



UNIVERSIDADE DE ÉVORA

DEPARTAMENTO DE MATEMÁTICA

**Uma Abordagem com Equações Estruturais às
Dimensões do Desenvolvimento Sustentável**

João Paulo Pires Saramago

Orientação: Professora Doutora Ana Maria Amorim
Sampaio

Mestrado em Modelação Estatística e Análise de Dados

Dissertação

Évora, 2014

Universidade de Évora
Escola de ciências e tecnologia

João Paulo Pires Saramago

Uma Abordagem com Equações Estruturais às Dimensões do Desenvolvimento Sustentável

Trabalho realizado sob orientação da
Professora Doutora Ana Maria Amorim Sampaio

Agradecimentos

É com enorme alegria e sinceridade que agradeço à professora doutora Ana Maria Amorim Sampaio, orientadora desta investigação, pelo interesse e atenção com que acompanhou este projecto, e por toda a referência científica essencial, estimulante e esclarecida que dispensou ao longo do trabalho.

MUITO OBRIGADO!

“Uma Abordagem com Equações Estruturais às Dimensões do Desenvolvimento Sustentável”

Resumo:

O desenvolvimento sustentável é um conceito multidimensional que ocupa um lugar de destaque nos programas internacionais direccionados para a resolução dos problemas colocados pela globalização, através da promoção da qualidade de vida (QV) das populações sem comprometer o bem-estar das gerações futuras. Neste trabalho foi analisado, ao nível de 215 países e para o ano de 2010, o efeito de uma variável latente, qualidade da governança (Gov) na qualidade de vida (QV), também latente. A abordagem com equações estruturais e o método dos Mínimos Quadrados Parciais (PLS) foram utilizados na estimação dos parâmetros. Apesar de terem sido detectadas diferenças entre métodos e amostras, os resultados obtidos permitem concluir, para a generalidade dos países analisados, da significância da trajectória estrutural de Gov em QV, da importância do estado de direito e da eficácia governamental em Gov, da facilidade de acesso ao saneamento básico, do índice de mortalidade infantil e da pegada ecológica na QV.

“Sustainable Development Dimensions: A Structural Equation Modelling Approach”

Abstract:

Sustainable development is an important multidimensional concept. It plays an important role in the resolution of issues caused by globalization promoting population quality of life without compromising the well - fare of future generations. The impact of Quality of Governance (Gov) on Quality of Life (QV) has been estimated through Structural Equation Modelling and Partial Least Squares. The study sample consists of 215 countries, analyzed in 2010. Besides differences detected at the levels of sample dimensions and methods, results show the significance of the structural path, the importance of rule of law and governmental efficacy on QG, of child mortality rate, sanitation facilities and ecological footprints on QV.

Índice

| | |
|--|-----------|
| 1. Introdução..... | 7 |
| 1.1. Os métodos estatísticos: <i>Análise de equações estruturais</i> | 8 |
| 1.2. Objectivos gerais e específicos | 9 |
| 1.3. Estrutura da tese | 10 |
| 2. O Desenvolvimento Sustentável | 11 |
| 2.1. Dimensões da sustentabilidade..... | 13 |
| 2.2. Medindo a sustentabilidade | 15 |
| 2.3. A Esfera Política..... | 19 |
| 3. Análise de equações estruturais (AEE) | 21 |
| 3.1.1. Variáveis em AEE | 22 |
| 3.1.2. Etapas da Análise de Equações Estruturais | 30 |
| 3.2. Métodos assentes na matriz de covariâncias (CBSEM: ML), na matriz de variâncias (PLS) e Bayesianos (Método de Monte Carlo-MC) | 57 |
| 3.3. Métodos baseados na matriz de covariâncias – CBSEM | 58 |
| 4. Métodos baseados na matriz de variâncias (VBSEM) - mínimos quadrados parciais (PLS) | 64 |
| 5. VBSEM (PLS) versus CBSEM (ML) | 75 |
| 6. A simulação na AEE..... | 80 |
| 7. Variáveis, Amostras e Modelo teórico..... | 83 |
| 7.1.1. Variável latente independente | 83 |
| 7.1.2. Variável latente dependente | 84 |
| 7.2. Amostra | 88 |
| 7.3. Modelo de Análise | 94 |
| 8. Resultados..... | 96 |
| 8.1. Eixo A: <i>Análise Exploratória</i> | 97 |
| 8.1.1. Análise Estatística Multivariada | 97 |
| 8.1.2. Análise estatística univariada | 101 |
| 8.2. Eixo B: <i>Avaliação do modelo conceptual com o método baseado na matriz de covariâncias – CBSEM.</i> | 117 |
| 8.2.1. Modelo de Medida e Estrutural com método CBSEM - Amostra total (n=215) | 117 |
| 8.2.2. Modelo de medida e estrutural com método CBSEM - Países subdesenvolvidos (N=147). | 119 |
| 8.2.3. Modelo de medida e estrutural com método CBSEM - Países desenvolvidos (N=68). | 121 |

| | | |
|--------|---|-----|
| 8.2.4. | <i>Modelo de medida e estrutural com método CBSEM - Países com rendimento baixo (N=38)</i> | 124 |
| 8.2.5. | <i>Modelo de medida e estrutural com método CBSEM - Países com rendimento médio-baixo (N=52)</i> | 126 |
| 8.2.6. | <i>Modelo de medida e estrutural com método CBSEM - Países com rendimento médio-alto (N=58)</i> | 128 |
| 8.3. | <i>Eixo C: Avaliação do modelo conceptual com o método baseado na matriz de variâncias – PLS</i> | 131 |
| 8.3.1. | <i>Modelo de Medida e Estrutural com método PLS - Amostra completa (n=215)</i> | 131 |
| 8.3.2. | <i>Modelo de Medida e Estrutural com método PLS - Países desenvolvidos (n=68)</i> 133 | |
| 8.3.3. | <i>Modelos de medida e estrutural com método PLS - Países subdesenvolvidos (N=147)</i> | 136 |
| 8.3.4. | <i>Análise dos modelos de medida e estrutural com método PLS - Países com rendimento baixo (n=38)</i> | 138 |
| 8.3.5. | <i>Modelo de medida e estrutural com método PLS - países com rendimento médio-baixo (N=52)</i> | 140 |
| 8.3.6. | <i>Modelo de medida e estrutural com método PLS - Países com rendimento médio-alto (N=58)</i> | 142 |
| 8.4. | <i>Eixo D: Comparação dos coeficientes estruturais entre os diferentes subgrupos</i> | 145 |
| 8.5. | <i>Eixo E Comparação das propriedades dos estimadores utilizados nos métodos CBSEM (ML) e PLS, assentes no processo de reamostragem bootstrap através de uma simulação de Monte Carlo</i> | 147 |
| 9. | Discussão de Resultados | 149 |
| 10. | Conclusão | 152 |

Índice de tabelas

| | |
|--|-----|
| Tabela 2.1 - Indicadores do Desenvolvimento sustentável segundo a OCDE | 18 |
| Tabela 3.1 - As variáveis na notação LISREL | 26 |
| Tabela 3.2 - Parâmetros matriciais na notação LISREL | 27 |
| Tabela 3.3 - Vantagens e desvantagens dos métodos de tratamento de dados perdidos | 34 |
| Tabela 3.4 - Medidas de Ajuste Geral do Modelo de equações estruturais..... | 51 |
| Tabela 5.1 - Características de CBSEM e PLS..... | 78 |
| Tabela 7.1 - Lista de Países constituintes da amostra total em estudo..... | 90 |
| Tabela 7.2 - Grupo formado pelos países desenvolvidos segundo o critério do Banco Mundial..... | 91 |
| Tabela 7.3 - Grupo formado pelos países subdesenvolvidos segundo o critério do Banco Mundial..... | 92 |
| Tabela 7.4 - Grupo formado pelos países com rendimento baixo segundo o critério do Banco Mundial..... | 93 |
| Tabela 7.5 - Grupo formado pelos países com rendimento médio-baixo segundo o critério do Banco Mundial..... | 93 |
| Tabela 7.6 - Grupo formado pelos países com rendimento médio-alto segundo o critério do Banco Mundial..... | 94 |
| Tabela 8.1.1 - Estatísticas descritivas multivariadas das da amostra total e respectivos subgrupos - variável latente Governança..... | 97 |
| Tabela 8.1.2 - Estatísticas descritivas multivariadas da amostra total e respectivos subgrupos - variável latente Qualidade de Vida..... | 98 |
| Tabela 8.1.3 - Estatísticas descritivas dos indicadores da variável latente Governança..... | 102 |
| Tabela 8.1.4 - Estatísticas descritivas dos indicadores da variável latente Qualidade de Vida..... | 109 |
| Tabela 8.2.1 - Estatísticas da análise factorial confirmatória da variável latente Governança – amostra total (N=215)..... | 118 |
| Tabela 8.2.2 - Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida – amostra total (N=215)..... | 118 |
| Tabela 8.2.3 - Estatísticas da análise factorial confirmatória da variável latente Governança - Países subdesenvolvidos (N=147)..... | 120 |

| | |
|--|-----|
| Tabela 8.2.4 - Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países subdesenvolvidos (N=147)..... | 120 |
| Tabela 8.2.5 - Estatísticas da análise factorial confirmatória da variável latente Governança - Países desenvolvidos (N=68)..... | 122 |
| Tabela 8.2.6 - Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países desenvolvidos (N=68)..... | 126 |
| Tabela 8.2.7 - Estatísticas da análise factorial confirmatória da variável latente Governança - Países com rendimento baixo (N=38)..... | 124 |
| Tabela 8.2.8 - Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países com rendimento baixo (N=38)..... | 125 |
| Tabela 8.2.9 - Estatísticas da análise factorial confirmatória da variável latente Governança - Países com rendimento médio baixo (N=52)..... | 126 |
| Tabela 8.2.10 - Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países com rendimento médio baixo (N=52)..... | 127 |
| Tabela 8.2.11 - Estatísticas da análise factorial confirmatória da variável latente Governança - Países com rendimento médio alto (N=58)..... | 129 |
| Tabela 8.2.12 - Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países com rendimento médio alto (N=58)..... | 129 |
| Tabela 8.3.1 - Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança - amostra total (N=215)..... | 132 |
| Tabela 8.3.2 - Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – amostra total (N=215)..... | 133 |
| Tabela 8.3.3 - Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap - amostra total (N=215)..... | 133 |
| Tabela 8.3.4 - Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança – Países desenvolvidos (n=68)..... | 134 |
| Tabela 8.3.5 - Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países desenvolvidos (N=68)..... | 135 |
| Tabela 8.3.6 - Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países desenvolvidos (N=68)..... | 136 |
| Tabela 8.3.7 - Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança – Países subdesenvolvidos (N=147)..... | 136 |
| Tabela 8.3.8 - Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países subdesenvolvidos (N=147)..... | 137 |

| | |
|--|-----|
| Tabela 8.3.9 - Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países subdesenvolvidos (N=147)..... | 138 |
| Tabela 8.3.10 - Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança – Países com rendimento baixo (N=38)..... | 139 |
| Tabela 8.3.11 - Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países com rendimento baixo (N=38)..... | 140 |
| Tabela 8.3.12 - Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países com rendimento baixo (N=38)..... | 140 |
| Tabela 8.3.13 - Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países com rendimento médio baixo (N=52)..... | 141 |
| Tabela 8.3.14 - Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países com rendimento médio baixo (N=52)..... | 141 |
| Tabela 8.3.15 - Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países com rendimento médio baixo (N=52)..... | 142 |
| Tabela 8.3.16 - Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança – Países com rendimento médio alto (N=58)..... | 143 |
| Tabela 8.3.17 - Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países com rendimento médio alto (N=58)..... | 143 |
| Tabela 8.2.18 - Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países com rendimento médio alto (N=58)..... | 144 |
| Tabela 8.4.1 - Análise e comparação dos coeficientes estruturais (Governança-> Qualidade de Vida) com o método CBSEM e PLS..... | 145 |
| Tabela 8.4.2 - Estatísticas resultantes da análise multigrupos com os métodos CBSEM e PLS..... | 146 |
| Tabela 8.5 - viés médio e erros padrão do modelo de medida e estrutural para cada tamanho amostral (n) e método de estimação (ML e PLS)..... | 147 |

Índice de Figuras

| | |
|--|-----|
| Figura 1 - Objectivo geral do estudo..... | 9 |
| Figura 2.1 (a) - Diagrama representando os quatro pilares do DS: Económico, Institucional e Social, envolvidos pelos limites do pilar Ambiental..... | 14 |
| Figura 2.1 (b) - Diagrama representando os quatro pilares complementares do DS - Económico, Institucional, Social, e Ambiental..... | 15 |
| Figura 2.2 - Relações chave entre as dimensões do Desenvolvimento Sustentável..... | 16 |
| Figura 3.1 - Diferentes tipos de relações em AEE..... | 24 |
| Figura 3.2 - Diagramas de trajectória de um modelo de medida e estrutura..... | 25 |
| Figura 3.3: representação gráfica de um modelo de equações estruturais..... | 28 |
| Figura 3.4 - Exemplo de um modelo 'reflexivo' (A) e de um modelo 'formativo' (B)..... | 29 |
| Figura 3.5 - Exemplo de um diagrama de caminhos..... | 31 |
| Figura 3.6 - Exemplo da transformação de um diagrama de caminhos em equação estrutural..... | 32 |
| Figura 3.7 - Modelo factorial confirmatório sub-identificado..... | 41 |
| Figura 3.8 - Modelo factorial confirmatório exactamente identificado..... | 41 |
| Figura 3.9 - Modelo factorial confirmatório sobre identificado..... | 42 |
| Figura 7.2 – Modelo conceptual em estudo..... | 94 |
| Figura 7.1: Sistema hierárquico de índices estatísticos, critério parcial e indicadores sintéticos da qualidade de vida usados no estudo (de acordo com S. Aivazian)..... | 85 |
| Figura 8.1.1 - Gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança e Qualidade de Vida - amostra total..... | 98 |
| Figura 8.1.2 - Gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança e Qualidade de Vida – Países subdesenvolvidos..... | 99 |
| Figura 8.1.3 - Gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança e Qualidade de Vida – Países desenvolvidos..... | 99 |
| Figura 8.1.4 - Gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança e Qualidade de Vida – Países com rendimento baixo..... | 100 |
| Figura 8.1.5 - Gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança e Qualidade de Vida – Países com rendimento médio baixo..... | 100 |

| | |
|--|-----|
| Figura 8.1.6 - Gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança e Qualidade de Vida – Países com rendimento médio alto..... | 101 |
| Figura 8.1.7 - Caixas de bigodes da variável manifesta voz e responsabilização (va), para os seis grupos de países- variável latente Governança..... | 103 |
| Figura 8.1.8 - Caixas de bigodes da variável manifesta estabilidade política e ausência de violência (sta), para os seis grupos de países- variável latente Governança..... | 104 |
| Figura 8.1.9 - Caixas de bigodes da variável manifesta eficácia governamental (eg), para os seis grupos de países- variável latente Governança..... | 105 |
| Figura 8.1.10 - Caixas de bigodes da variável manifesta qualidade regulatória (qr), para os seis grupos de países- variável latente Governança..... | 106 |
| Figura 8.1.11 - Caixas de bigodes da variável manifesta estado de direito (rl), para os seis grupos de países- variável latente Governança..... | 107 |
| Figura 8.1.12 - Caixas de bigodes da variável manifesta controlo da corrupção (cc), para os seis grupos de países- variável latente Governança..... | 108 |
| Figura 8.1.13 - Caixas de bigodes da variável manifesta taxa de literacia (LT), para os seis grupos de países- variável latente Qualidade de Vida..... | 110 |
| Figura 8.1.14 - Caixas de bigodes da variável manifesta índice de mortalidade infantil (IMR), para os seis grupos de países- variável latente Qualidade de Vida..... | 111 |
| Figura 8.1.15 - Caixas de bigodes da variável manifesta facilidade de acesso ao saneamento básico (SN), para os seis grupos de países- variável latente Qualidade de Vida..... | 112 |
| Figura 8.1.16 - Caixas de bigodes da variável manifesta pegada ecológica (EF), para os seis grupos de países- variável latente Qualidade de Vida..... | 113 |
| Figura 8.1.17 - Caixas de bigodes da variável manifesta índice de percepção ambiental (EPI), para os seis grupos de países- variável latente Qualidade de Vida..... | 114 |
| Figura 8.1.18 - Caixas de bigodes da variável manifesta índice de liberdade económica mundial (EFW), para os seis grupos de países- variável latente Qualidade de Vida..... | 115 |
| Figura 8.1.19 - Caixas de bigodes da variável manifesta produto interno bruto (GDP), para os seis grupos de países- variável latente Qualidade de Vida..... | 116 |
| Figura 8.2.1 - Modelo estrutural CBSEM com 8 resíduos correlacionados (ϵ_2 e ϵ_4 , ϵ_3 e ϵ_4 , ϵ_7 e ϵ_9 , ϵ_{10} e ϵ_{13}) - Amostra total (N=215)..... | 119 |
| Figura 8.2.2 - Modelo estrutural CB-SEM com 6 resíduos correlacionados (ϵ_2 e ϵ_3 , ϵ_2 e ϵ_4 , ϵ_3 e ϵ_4) – Países subdesenvolvidos (N=147)..... | 121 |
| Figura 8.2.3 - Modelo estrutural CBSEM com 6 resíduos correlacionados (ϵ_2 e ϵ_5 , ϵ_2 e ϵ_5 , ϵ_3 e ϵ_5) – Países desenvolvidos (N=68)..... | 123 |

| | |
|---|-----|
| Figura 8.2.4 - Modelo estrutural com método CBSEM - Países com rendimento baixo (N=38)..... | 125 |
| Figura 8.2.5 - Modelo estrutural CBSEM com 6 resíduos correlacionados (ϵ_2 e ϵ_3 , ϵ_2 e ϵ_4 , ϵ_3 e ϵ_4) e sem o indicador relativo á pegada ecológica (EF) – Países desenvolvidos (N=68)..... | 128 |
| Figura 8.2.6 - Modelo estrutural CBSEM com 6 resíduos correlacionados (ϵ_2 e ϵ_3 , ϵ_2 e ϵ_5 , ϵ_3 e ϵ_4) – Países com rendimento médio alto (N=58)..... | 130 |
| Figura 8.3.1 - Pesos factoriais estandardizados (loadings) dos indicadores dos blocos Governança e Qualidade de Vida - Amostra total (N=215)..... | 132 |
| Figura 8.3.2 - Pesos factoriais estandardizados (loadings) dos indicadores dos blocos Governança e Qualidade de Vida – Países desenvolvidos (N=68)..... | 135 |
| Figura 8.3.3 - Pesos factoriais estandardizados (loadings) dos indicadores dos blocos Governança e Qualidade de Vida – Países subdesenvolvidos (N=147)..... | 137 |
| Figura 8.3.4 - Pesos factoriais estandardizados (loadings) dos indicadores dos blocos Governança e Qualidade de Vida – Países com rendimento baixo (N=38)..... | 139 |
| Figura 8.3.5 - Pesos factoriais estandardizados (loadings) dos indicadores dos blocos Governança e Qualidade de Vida – Países com rendimento médio baixo (N=52)..... | 141 |
| Figura 8.3.6 - Pesos factoriais estandardizados (loadings) dos indicadores dos blocos Governança e Qualidade de Vida – Países com rendimento médio alto (N=58)..... | 143 |

1. Introdução

O interesse pela investigação acerca do desenvolvimento sustentável (DS) das economias tem sido alvo de atenção crescente, na medida em que, englobando as principais estruturas do âmbito social, institucional, ambiental e económico, aborda os temas centrais necessários à construção de uma sociedade mais desenvolvida. Para ser sustentável o desenvolvimento deve providenciar um balanço entre os objectivos económicos, sociais, ambientais e institucionais (considerados como os quatro principais pilares do desenvolvimento sustentável) das sociedades com o objectivo de maximizar o bem-estar presente, sem comprometer os recursos e necessidades das gerações vindouras (World Commission on Environment and Development, 1987).

A união europeia estabeleceu uma estratégia para promover o DS com o objectivo de contribuir e identificar maneiras das economias lidarem com a globalização e os problemas associados. Por exemplo, verifica-se que muitos países têm vindo a beneficiar de um notável aumento do crescimento económico, nomeadamente através de um mercado progressivamente mais aberto e da liberalização do investimento estrangeiro directo (IDE), mostrando que a globalização pode continuar a gerar crescimento económico com os custos indesejáveis a todos os níveis largamente discutidos na literatura mais recente sobre o desenvolvimento.

Os países subdesenvolvidos avançaram em vários aspectos. As suas exportações e produções diversificaram significativamente; a esperança média de vida aumentou, e para muitos, a qualidade de vida melhorou. Contudo, para muitos países e indivíduos a pobreza, desemprego e exclusão permanecem (estimativas ILO – Departamento Internacional do Trabalho). Metade da população mundial vive com menos de 1.461 euros por dia e as desigualdades entre e dentro dos países continua a aumentar.

Até finais da década de 60, o rendimento dos cinco países mais ricos era 30 vezes superior ao dos cinco países mais pobres. Hoje em dia esse rendimento é cerca de 90 vezes superior. Cerca de um bilião de homens e mulheres estão desempregados ou com trabalhos precários, o trabalho infantil conta com 250 milhões de crianças e 80% da força laboral não tem acesso a protecção social básica (estimativas ILO). Além disso, muitos recursos naturais tais como água, terra, solo, biodiversidade, florestas e reservas piscatórias estão a ser exploradas para além dos seus limites causando danos irreversíveis ao meio ambiente.

A humanidade está consciente de que partilha um futuro comum e interligado e que a injustiça e todo o tipo de conflitos que possam surgir num lado do mundo tem repercussões directas na vizinhança. Para além do mais, pobreza e privação podem fomentar reacções de descontentamento criando condições para que problemas étnicos e religiosos tomem proporções extremas.

Em suma, existe consciência de que as necessidades materiais e ambientais são satisfeitas através do desenvolvimento económico, no entanto, o desenvolvimento social é de capital importância na medida em mostra ser possível melhorar aspectos como a justiça social, igualdade e segurança. Deste modo, ao englobar factores sociais, económicos, ambientais e

institucionais (também conhecidos como os 4 pilares do DS), o conceito de desenvolvimento sustentável abrange um vasto conjunto de indicadores tais como a pegada ecológica, produto interno bruto ou a facilidade de acesso ao saneamento básico, que permitem expressar as relações dinâmicas entre esses factores, evidenciando a sua importância no desenvolvimento das economias das nações o que se traduz numa melhoria da qualidade de vida das mesmas.

Uma das origens das tendências insustentáveis provém da relação complexa entre os mercados, a governança global e as políticas nacionais adoptadas por cada país. Neste contexto, e no âmbito de uma governança global mais eficaz, várias promessas tem vindo a ser realizadas, principalmente através dos acordos Bonn and Marrakech (Huq, 2002), nos quais a união europeia desempenhou um papel fundamental. Uma boa democracia e estado de direito são pré-requisitos determinantes ao DS, contudo, as respostas políticas aos desafios governamentais têm-se mostrado insuficientes a nível nacional, europeu e internacional. Com o objectivo de tornar a globalização sustentável é necessário, por um lado, um maior equilíbrio entre as forças de mercado globais e por outro, um maior equilíbrio da qualidade de governança global e instituições políticas. Uma participação activa e processos de decisão transparentes por parte das nações são componentes essenciais a uma boa governança, promovendo, deste modo, uma melhoria na qualidade de vida das mesmas.


1.1. Os métodos estatísticos: Análise de equações estruturais

A análise de equações estruturais (AEE) é uma técnica estatística multivariada que combina elementos da análise factorial e regressão linear e cujo objectivo é examinar uma estrutura de relações expressa através de um conjunto de equações que ilustram todas as relações entre as variáveis latentes em estudo. A técnica inerente à AEE baseada na análise da matriz de variância-covariância (CBSEM) também conhecida como LISREL (Relações Estruturais Lineares), e o método dos mínimos quadrados parciais (PLS), têm vindo a ganhar enorme popularidade como métodos chave na análise estatística multivariada nos últimos anos. Estas técnicas têm vindo a ser aplicadas em varias áreas científicas tais como na gestão de sistemas de informação (MIS) (Ringle, Sarstedt, & Straub, 2012), marketing (Reinartz, Heinlein, & Henseler, 2009) e psicologia (MacCallum & Austin, 2000). Apesar da semelhança entre as duas técnicas, existem várias diferenças entre elas, especialmente nas estimativas aproximadas que utilizam. Enquanto CBSEM se centra na estimação de um conjunto de parâmetros do modelo de modo que a matriz de covariância teórica implicada pelo sistema de equações estruturais seja o mais semelhante possível à matriz de covariância amostral, o método PLS estima os parâmetros do modelo de forma a maximizar a variância explicada para todos os constructos endógenos através de regressões de mínimos quadrados ordinários (Reinartz et al., 2009). Além disso, um extensivo estudo de simulação realizado por Reinartz et al. (2009) mostra que as estimativas dos parâmetros obtidas com PLS são mais precisas do que nos CBSEM quando o tamanho amostral é pequeno, o que acontece precisamente neste estudo aquando da divisão de países em subgrupos de menor dimensão.

1.2. Objectivos gerais e específicos

Deste modo, o objectivo central desta tese é desenvolver, testar e validar um modelo conceptual que consiga reflectir a Qualidade de Vida das populações em função da Qualidade de Governança (figura 1).

Figura 1 – Objectivo geral do estudo.



Para atingir o objectivo principal, foram estabelecidos os seguintes objectivos específicos:

- Criar um modelo de mensuração da Governança e da Qualidade de Vida e identificar, com base na literatura as variáveis latentes e manifestas que o permitem operacionalizar.
- Aplicar as duas técnicas inerentes à análise de equações estruturais (AEE), CBSEM e PLS para estimar, testar e validar o modelo teórico que define as relações hipotéticas em estudo.
- Realizar uma simulação de Monte Carlo no âmbito para comparar e analisar as diferentes propriedades dos estimadores resultantes da aplicação das duas técnicas inerentes à AEE.

1.3. Estrutura da tese

A seguinte tese está estruturada em 10 capítulos. Capítulo 1, Introdução; o capítulo 2 consiste na fundamentação teórica sobre a problemática do Desenvolvimento Sustentável, dando ênfase às suas principais dimensões, assim como aos indicadores subjacentes pelos quais é possível medi-lo. O capítulo 3 apresenta uma descrição pormenorizada dos principais aspectos da AEE, técnica pela qual se vai avaliar o modelo em estudo, assim como uma abordagem ao método mais utilizado na AEE (o método baseado na matriz de covariâncias-CBSEM). O 4º capítulo aborda a metodologia dos mínimos quadrados parciais (PLS), método alternativo ao método CBSEM, analisando as suas principais propriedades, vantagens e desvantagem em relação a outras metodologias. O 5º capítulo apresenta as principais diferenças entre o método CBSEM e o método PLS. O capítulo 6 incide sobre o papel da simulação na AEE, principalmente no que diz respeito às propriedades assintóticas dos estimadores utilizados nos métodos CBSEM e PLS. O capítulo 7 tem como objectivo descrever as amostras, as variáveis latentes e manifestas utilizadas no estudo, o modelo teórico conceptual especificado a partir de referências literárias, assim como as hipóteses de investigação subjacentes ao estudo. O capítulo 8 é destinado á apresentação e análise de resultados. Neste capítulo, os dados são analisados à luz das duas metodologias inerentes à AEE (CBSEM e PLS) tendo em conta a amostra global e cada um dos subgrupos designados (países desenvolvidos, países subdesenvolvidos, países com rendimento baixo, países com rendimento médio-baixo e países com rendimento médio alto). O 9º capítulo procura dar sentido aos resultados obtidos na secção anterior, abordando os resultados mais pertinentes provenientes da aplicação dos métodos CBSEM e PLS ao modelo conceptual Gov-QV nos seis grupos de países. Por último, com base nos principais elementos obtidos, concretizam-se, no capítulo 10, as principais conclusões, apresentam-se contributos para o conhecimento e para a prática e deixam-se algumas sugestões para futuras pesquisas.

2. O Desenvolvimento Sustentável

É fundamental nos dias que correm haver uma maior consciencialização colectiva relativamente a problemas inerentes à sociedade humana tais como a degradação ambiental, mudanças climáticas, empobrecimento ou desigualdades sociais. Estes problemas têm origem nas múltiplas interacções entre o homem e o meio ambiente, ganhando mais relevância à medida que a densidade populacional aumenta (Clark, 2003). A velocidade dessas interacções, juntamente com o consumo desenfreado que se vive hoje em dia, para além de reduzir consideravelmente os recursos naturais que outrora dispúnhamos, criou também lacunas em vários sectores da sociedade que por sua vez se traduzem em desigualdades sociais, económicas e institucionais. Em suma, tudo isto se pode resumir numa palavra, insustentabilidade.

É neste contexto que nasce o conceito de desenvolvimento sustentável (DS), que começa a ter ampla aceitação nos finais dos anos 80, após o seu aparecimento no relatório “Our Common Future”, igualmente conhecido como “The Brundtland Report”, (World Commission on Environment and Development (WCED). Our Common Future; Oxford University Press: New York, NY, USA, 1987), relatório este fruto do resultado de uma reunião de uma comissão da ONU criada para propor uma agenda global para a “mudança” do conceito e das práticas de desenvolvimento. O relatório assinalava a urgência de repensarmos os nossos modos de vida e de governo.

Existem dois pontos essenciais para atingir o conceito de DS. Em primeiro lugar, o reconhecimento de que a economia cresce por si só não é suficiente para resolver os problemas do mundo: os aspectos económicos, sociais e ambientais de qualquer acção devem estar interligados. Considerar um destes aspectos isoladamente pode provocar erros de julgamento e resultados “insustentáveis”. Por exemplo, o facto de nos centrarmos apenas nas margens de lucro, levou no passado a danos sociais e ambientais consideráveis. No entanto, cuidar do ambiente e fornecer serviços que as pessoas necessitam depende, pelo menos parcialmente, de recursos económicos.

Em segundo lugar, a natureza interligada do desenvolvimento sustentável exige que se ultrapassem os limites geográficos ou institucionais, para se coordenarem estratégias e elaborarem boas decisões. Os problemas raramente se circunscrevem a jurisdições predefinidas, como é o caso de uma agência governamental ou uma única vizinhança, e as soluções inteligentes requerem que a cooperação faça parte do processo de elaboração de decisões.

Contudo, DS é um conceito de difícil definição uma vez que o contexto em que se insere varia de acordo com diversas situações, seja devido às diferenças estruturais entre os países, seja devido às prioridades políticas que aí se estabelecem, ou mesmo às prioridades que cada autor/investigador estabelece para si mesmo de acordo com o que pensa ser o melhor caminho para a sustentabilidade dentro das diferentes campos ou áreas em de investigação.

Deste modo, no Brasil por exemplo, o termo agricultura sustentável refere-se ao tipo de práticas agrícolas que mantém tanto a qualidade de nutrientes do solo permitindo o uso da

terra a longo termo e a integridade ecológica e ambiental do solo, água e sistemas de regadio e que ao mesmo tempo seja rentável para os agricultores (Caviglia, J.L. Sustainable Agriculture in Brazil; Edward Elgar: Cheltenham, UK, 1999). Já na China, é utilizada uma definição mais ampla no que diz respeito à agricultura sustentável (Zhang, R.; Zhang, H.; Zhang, R. Environmental Protection and Sustainable Agricultural Development in China; Beijing Publishing House: Beijing, China, 2001.), na medida em que, ao mesmo tempo que se dá prioridade à produção de comida e segurança da população, assegura-se também um balanço entre auto-suficiência e produção dos mercados, promovendo ao mesmo tempo emprego rural, geração de riqueza para aliviar a pobreza, gestão de recursos naturais e protecção ambiental (Shi, T. Operationalizing sustainability: an emerging eco-philosophy in Chinese ecological agriculture. J. Sustain. Agri. 2004).

Uma tentativa, realizada por Brundtland diz que “o desenvolvimento pode ser considerado como um compromisso entre as exigências crescentes quer da protecção ambiental quer do desenvolvimento económico” (World Commission on Environment and Development (WCED). Our Common Future; Oxford University Press: New York, NY, USA, 1987). Originalmente, ao designar o termo desenvolvimento, apenas se estava a fazer referência ao desenvolvimento económico, contudo, posteriormente, este termo foi alargado englobando também quer o desenvolvimento social quer o desenvolvimento cultural.

Para Brundtland, a noção de desenvolvimento sustentável passa não só por um crescimento económico acompanhado de um reduzido impacto ambiental, mas pressupõe também que a terra seja capaz de produzir recursos suficientes que consigam satisfazer as necessidades presentes e futuras da humanidade. Contudo devido ao facto de ainda não existirem evidências suficientes que corroborem esta hipótese, surgem questões tais como: o que se deve fazer se não houver recursos suficientes que satisfaçam as necessidades presentes e futuras? Ou ainda: que necessidades estão comprometidas devido à falta de recursos? (Liu, 2009).

Ainda assim, ao enunciar o termo “necessidades”, Brundtland deixa novamente a noção de desenvolvimento sustentável sujeita a novas interpretações (UNESCO, Paris, France, 2004), uma vez que “necessidades” pode simplesmente dizer respeito às necessidades básicas como comida e abrigo para alguns, mas pode significar muito mais para outros. Clark and Kates afirmam que existe uma hierarquia de bens necessários que favorece crianças e pessoas em “desastres” e que dá prioridade à alimentação e nutrição, seguido de educação, habitação e emprego (2005 World Summit Outcome: New York, NY, USA, 2005). As pessoas nos países desenvolvidos podem considerar carros, ar condicionado e viagens como bens necessários, os quais não são viáveis para a maioria da população dos países mais pobres enquanto o governo da Coreia do norte, por exemplo, pode incluir armas nucleares nos seus bens necessários, mesmo que as pessoas não tenham comida suficiente (Press Conference on National Day Military Parade, 24 September 2009). Em suma, é sempre difícil determinar se os bens necessários são alcançados/preenchidos e a que níveis o são.

Será que tem que ser alcançado 100% dos bens necessários? Devemos medir a sua média por país ou por região? Os bens necessários deverão assistir toda a gente ou apenas a maioria da população? Dados os níveis elevados de desigualdade a nível monetário, os países mais ricos

ainda tem pessoas pobres cujas necessidades básicas ainda estão por satisfazer, enquanto alguns países pobres tem bilionários. Por sua vez, os bilionários podem argumentar que o seu país ainda é pobre e precisa de crescimento económico, contudo, este crescimento é muitas vezes alcançado à custa da exploração de pessoas pobres e do meio ambiente.

2.1. Dimensões da sustentabilidade

No âmago do DS encontra-se a necessidade de considerar simultaneamente “quatro pilares”: social, económico, ambiental e institucional. Seja qual for o contexto, a ideia base é sempre a mesma – os indivíduos, habitats, sistemas económicos e institucionais estão interligados. O contexto histórico, económico, social e político de cada país é único, mas os princípios básicos do desenvolvimento sustentável aplicam-se a todos. O desenvolvimento económico é essencial, mas o crescimento por si só, sem considerar todos os factores que contribuem para o bem-estar da sociedade não é sustentável. Por exemplo, o crescimento económico está geralmente associado a níveis mais altos de educação e esperança de vida ao nível dos países (associação realizada através de indicadores amostrais). No entanto, não podemos ignorar que o crescimento económico poderá ter sido alcançado não só à custa da delapidação dos recursos naturais com danos irreversíveis ao nível do equilíbrio ambiental desejável, como também de um acentuar das desigualdades sociais, comprometendo a viabilidade das gerações futuras.

Porritt afirma, por sua vez, que a economia representa um subsistema da sociedade humana e que este por sua vez representa um subsistema da vida total na Terra (a biosfera), e nenhum subsistema se consegue expandir para lá da capacidade total do sistema total (Porritt, J. *Capitalism as if the World Mattered*; Earthscan: London, UK, 2006). (figura 2.1a).

Deste modo, foram propostas outras dimensões de sustentabilidade. Uma que foi bem aceite foi a noção de sustentabilidade cultural (SC), que segundo a “universal declaration on cultural diversity”(UNESCO: Paris, France; 2001) é tao necessária à humanidade como por exemplo a biodiversidade é importante para a natureza. SC é uma das raízes do DS funcionando como um meio de alcançar uma maior satisfação intelectual, emocional, moral e espiritual na existência.

Figura 2.1 (a): Diagrama representando os quatro pilares do DS: Económico, Institucional e Social, envolvidos pelos limites do pilar Ambiental.





Figura 2.1 (b): Diagrama representando os quatro pilares complementares do DS - Económico, Institucional, Social, e Ambiental.



2.2. Medindo a sustentabilidade

À primeira vista, medir o desenvolvimento sustentável parece ser impossível. O tema é muito vasto e possui muitas vertentes – alteração climática, protecção social das crianças, éticas de negócio, política governamental, tendências dos consumidores, só para mencionar algumas. Sabemos que o desenvolvimento sustentável envolve variáveis económicas, sociais e ambientais – e todas elas devem ser medidas de alguma forma. Normalmente as medições são realizadas através de indicadores pois é com base nestes que as políticas de desenvolvimento sustentável assentam.


Existem indicadores tradicionais macroeconómicos em abundância, (como é o caso do produto interno bruto (PIB) e da produtividade); indicadores ambientais, (consumo de água e emissões atmosféricas); estatísticas sociais, (esperança de vida e níveis de ensino). Mas quais serão os indicadores mais importantes para medir desenvolvimento sustentável?

A questão é ainda mais dificultada pelo facto de o desenvolvimento sustentável ser, para além de multidimensional, ser um conceito dinâmico. Para se quantificar o desenvolvimento sustentável é necessário conciliar os vários cenários, incluindo horizontes temporais. Os fenómenos económicos, sociais e ambientais actuam em ritmos diferentes uns dos outros. Consideremos a economia: se se planear um grande projecto de energia, tem que se pensar pelo menos nos próximos 50 anos, mas se se negociar nos mercados financeiros, os nano

segundos que levam os dados dos preços a oscilarem de uma troca para outra podem significar ganhos ou perdas substanciais. O ambiente mostra como o ritmo da troca pode acelerar de repente, tal como os stocks de peixe desaparecem rapidamente após durante muitos anos terem diminuído lentamente.

Além disso, temos que ter presente o facto de que o desenvolvimento sustentável é um processo que interliga o que aconteceu no passado ao que agora fazemos, e que por sua vez influencia as opções e resultados do futuro. O desenvolvimento de medidas não é um exercício puramente estatístico ou técnico na medida em que afecta duas das áreas mais sensíveis em todas as sociedades: responsabilidade governamental e participação social. Um ingrediente-chave do processo democrático é a medição do progresso do DS com informação fiável. Torna os governos mais responsáveis e proporciona às pessoas uma ferramenta para participarem de forma mais activa na definição e avaliação dos objectivos das políticas (UN, OECD et. al. (2003), Handbook of National Accounting, Integrated Environmental and Economic Accounting 2003 (SEEA), United Nations, New York).

Figura 2.2:Relações chave entre as dimensões do Desenvolvimento Sustentável.



Para ilustrar melhor estas situações, podemos recorrer ao exemplo da figura 2.2 onde estão representadas as dimensões chave do desenvolvimento sustentável. Olhando para a figura podemos detectar imediatamente um conjunto de seis relações entre as três dimensões, são estas:

- 1) Efeito da actividade económica no ambiente (uso de recursos, descargas poluentes, resíduos).
- 2) Efeito da actividade ambiental na economia (impacto dos recursos naturais, na economia e no emprego).
- 3) Efeito da actividade ambiental na sociedade (contributo dos recursos naturais na saúde, qualidade de vida e nas condições laborais).
- 4) Efeitos da actividade social no ambiente (impacto das mudanças demográficas, padrões de consumo, informação e educação ambiental, estruturas legais e institucionais, no contexto ambiental).
- 5) Efeito da actividade social na economia (impacto da força laboral, estrutura familiar e populacional, prática educacional; níveis de consumo, estruturas legais e institucionais no contexto económico).
- 6) Efeito da actividade económica na sociedade (níveis salariais, igualdade e emprego).

Para medir todas estas relações existe uma variedade enorme de indicadores que devem ser escolhidos duma forma clara e que proporcionem uma fácil interpretação, principalmente no âmbito da ligação a questões políticas, facilitando assim a tomada de decisão quer por parte das entidades governamentais quer por parte das entidades públicas. Deste modo, para cada dimensão do desenvolvimento sustentável são escolhidos uma serie de indicadores, que podem diferir de país para país de acordo com as estratégias de cada um para a sustentabilidade. Uma tentativa pensada pela OCDE passaria por eleger um conjunto base e reduzido de indicadores acessíveis e facilmente compreensíveis, em vez de uma longa lista. Deste modo, a lista que se segue contém um conjunto de indicadores que permitem, segundo a OCDE medir rapidamente se a população consegue manter o activo circulante tal como as necessidades atuais relativamente aos parâmetros do desenvolvimento sustentável. (tabela 2.1)(OECD, 2001):

Tabela 2.1: indicadores do Desenvolvimento sustentável segundo a OCDE.

| Tema | Indicadores |
|---|---|
| Bens ambientais | |
| Qualidade do ar | Gases de efeito de estufa (GHG), emissões de CO ₂ e NO ₂ (GWP-Potencial de Aquecimento Global) |
| Recursos hídricos | Consumo da água (Litros por habitante e por dia) |
| Recursos energéticos | Consumo de recursos energéticos (percentagem do consumo total de energia) |
| Biodiversidade | Tamanho da área protegida como parte da área total (percentagem da superfície do Território) |
| Bens económicos | |
| Activos produzidos | Produto interno bruto (PIB) (Euro) |
| Activos de P & D | Evolução do valor acrescentado bruto (VAB) por sectores (Percentagem do Valor Acrescentado Bruto (VAB)) |
| Activos financeiros | Activos externos líquidos e saldo da conta corrente (Euro). |
| Capital humano | |
| Stock de capital humano | Proporção da população com qualificações secundário/superior (Percentagem relativa ao número de indivíduos no grupo etário) |
| Investimento em capital humano | Despesa na educação (Euro) |
| Desvalorização do capital humano | Taxa e nível de desemprego (Percentagem de população desempregada relativamente à população activa) |
| Consumo | Despesa total do agregado familiar, quantidade de resíduos a nível municipal. |
| Distribuição de rendimentos | Coeficientes GINI |
| Saúde | Taxa de mortalidade infantil (Permilagem (número de mortes registadas por cada 1.000 nados-vivos) |
| Situação laboral/emprego | Razão entre emprego e população |
| Educação | Taxa de analfabetismo (Percentagem) |
| Fonte: OECD (2001), Sustainable Development: Critical Issues | |

2.3. *A Esfera Política*

O papel que os governos poderão ter no DS deveria ser determinante para assegurar o mesmo. A capacidade de influenciar os comportamentos e coordenar esforços nas populações pode fazer toda a diferença na produção de resultados substanciais em termos de DS. Um dos maiores desafios que os governos enfrentam é encontrar as ferramentas políticas certas para impulsionar as práticas de produção e de consumo correctas e evitar situações que sejam prejudiciais para a Qualidade de Vida das populações. Convencer os produtores e os consumidores a mudar nem sempre é a forma mais eficiente para lidar com as questões, nem é suficiente para produzir uma mudança suficientemente grande a uma escala global. Geralmente, o produtor ou consumidor individual possui pouco poder e pouco interesse para mudar as coisas. No entanto, os governantes têm a grande vantagem de legislar e impor regulamentações. Uma das soluções à sua disposição é simplesmente proibir produtos e comportamentos que parecem ser mais nocivos que benéficos. Foi o que aconteceu com os CFCs (gases usados em refrigerantes e sprays aerossol) que prejudicavam a camada de ozono.

Os impostos relacionados com o ambiente (“verdes” ou “ecoimpostos”) e comércio de direitos de emissão podem igualmente ser instrumentos eficazes. Podem forçar os poluidores (sejam eles produtores ou consumidores) a ter em conta os custos da poluição e podem ajudar a reduzir a procura de produtos nocivos. O imposto irlandês “plastax” de 2002 levou a uma redução de 90% da utilização de sacos de plástico.

Os governantes podem realizar várias tarefas que contribuam para o desenvolvimento sustentável e qualidade de vida das populações. Através da reunião e análises de dados, elaboração e coordenação das políticas, podem fornecer apoio e liderança para orientar a sociedade para uma determinada direcção. Podem fazer com que os interesses individuais não se desviem do bem comum. Os governos intervêm igualmente para lidar com o que os economistas designam por “fracassos de mercado”, situações nas quais as forças de mercado por si só não produzem o resultado mais eficaz. Dada a natureza global de muitos dos desafios que a sustentabilidade enfrenta, os países têm que cooperar aos mais elevados níveis para conceber e aplicar soluções. Os governos nacionais possuem a autoridade e o poder para tal e possuem igualmente os meios para se certificarem que as decisões são aplicadas.

Ao descrevermos o papel do governo no contexto do DS, é fácil criar a impressão que a governança para o desenvolvimento sustentável é meramente uma questão de identificar objectivos e, de seguida, implementar uma série de medidas e criar órgãos para supervisionar a aplicação dessas medidas. Não é assim. Quase todos os aspectos da economia, sociedade e os recursos físicos dos quais dependem no fim de contas, influenciam a sustentabilidade. Os resultados dependem de um número infinito de interações que agem em diferentes períodos de tempo e com importância variada. Nenhum modelo, por muito robusto que seja, nenhuma previsão por muito que seja suportada com análises estatísticas adequadas pode explicar toda a realidade. Os governantes que tentam implementar a sustentabilidade têm que lidar com esta incerteza. Não só os seus objectivos têm que ser sustentáveis, mas igualmente as estratégias e os instrumentos utilizados para os alcançar, têm que ser suficientemente

rigorosos para serem eficazes, mas suficientemente flexíveis para se adaptarem à medida que as circunstâncias e prioridades vão evoluindo. Face à incerteza, a própria governança tem que ser sustentável.

A incorporação de Crescimento Verde e Desenvolvimento Sustentável nas reformas estruturais

É importante agora, introduzir a noção de Crescimento Verde. O Crescimento Verde almeja o crescimento económico e desenvolvimento, ao mesmo tempo que assegura que as vantagens naturais são utilizadas de um modo sustentável continuando a providenciar os recursos e serviços ambientais nos quais o bem-estar humano permanece (OCDE, 2011).

O Crescimento Verde é um crescimento eficiente no que diz respeito à utilização de recursos naturais, ou seja, “limpo” na medida em que minimiza a poluição e impactos ambientais. Dá ênfase a um progresso económico sustentável a nível ambiental promovendo baixas emissões e desenvolvimento social inclusivo. O Crescimento Verde reduz significativamente os riscos ambientais e promove as sociedades ecológicas (UNEP, 2004).

Crescimento verde e desenvolvimento sustentável como motor do crescimento económico

As reformas estruturais baseadas em práticas e políticas verdes podem contribuir para o crescimento através de três formas: primeiro, estas podem promover a eficiência e ajudar ao crescimento capital natural, físico e humano disponível. Um solo bem gerido é mais produtivo, ambientes mais saudáveis contam com trabalhadores mais produtivos. Riscos naturais bem geridos resultam em baixas perdas de capitais resultantes de desastres naturais (Hallegatte, 2011). Adicionalmente, a imposição de taxas ambientais e a remoção de subsídios ineficientes cria um espaço fiscal adicional para os governos reduzirem taxas distorcidas ou subsídios verdes – bens, tais como transportes públicos ou acesso a água potável e serviços de higiene.

Em segundo lugar, as políticas verdes conseguem estimular a inovação e em terceiro as políticas verdes aumentam a resiliência aos choques ambientais ou económicas reduzindo a volatilidade dos preços dos recursos naturais.

3. *Análise de equações estruturais (AEE)*

A análise de Modelos de Equações estruturais (Structural Equation Modeling-SEM), ou simplesmente, Análise de Equações Estruturais (AEE) é uma abordagem metodológica de modelação generalizada, utilizada para testar a validade de modelos teóricos que definem relações estruturais, causais, hipotéticas, entre variáveis. Estas relações são representadas por parâmetros que indicam a magnitude e o sentido do efeito que ocorre entre elas, ou seja, descrevem hipóteses respeitantes a padrões de associações entre as variáveis no modelo teórico.

Por outras palavras, o objectivo principal da AEE passa por examinar um conjunto de relações e atribuir um valor quantitativo a cada uma, baseado nas covariâncias entre as variáveis. Esses valores quantitativos, referidos como estimativas dos parâmetros, são aproximações numéricas da força e direcção das relações entre variáveis, que poderão ser observadas na população (Bollen, 1989; Kline, 2011). Sendo uma aproximação comum em diversas áreas (e.g., educação, psicologia, sociologia, economia, pesquisa de marketing, etc. Monecke & Leisch, 2012), a AEE representa uma alternativa em relação à regressão múltipla no que diz respeito ao cálculo dos coeficientes provenientes dum sistema em que, tanto as variáveis predictoras como as variáveis resposta poderão estar interligadas de modos bastante complexos (e.g., algumas variáveis podem ser ambas resposta e predictoras e algumas variáveis resposta podem ter múltiplos preditores, etc.; Bollen, 1989; Haenlein & Kaplan, 2004; Kline, 2011). A AEE tem também como objectivo a identificação de um conjunto único de estimativas dos parâmetros (i.e., coeficientes estruturais, erros de medida, etc.) que minimizem a diferença total entre as covariâncias implicadas pelo modelo e aquelas observadas na população.

Os SEM são geralmente compostos por um ou vários modelos de medida e um modelo estrutural (Bollen, 1989; Kline, 2011). O modelo de medida (por vezes também referido como modelo exterior Ringle et al., 2009) conecta cada variável latente às variáveis manifestas correspondentes, especificando, deste modo, a síntese de múltiplas variáveis em variáveis compósitas (e por vezes latentes). O modelo estrutural (por vezes também conhecido como modelo interior; Ringle et al., 2009) conecta as variáveis latentes existentes no modelo. Um procedimento computacional é necessário para estimar os valores dos parâmetros que descrevem essas relações. No contexto da AEE, ambas as variáveis resposta e predictoras podem ser latentes ou observadas (Lee & Xia, 2008).

A AEE foi sendo desenvolvida na primeira metade do séc. XX a partir dos trabalhos seminais de Charles Spearman sobre a Análise Factorial (Spearman, 1904) e de Sewall Wright (1921, 1934) sobre a Análise de Trajectórias (Path Analysis). Na segunda metade do século XX o uso da AEE generalizou-se às ciências sociais e humanas após as contribuições de Jöreskog (1970), Keesling (1972) e Wiley (1973) relativas ao desenvolvimento de métodos de estimação para as estruturas de covariância dos modelos estruturais (Bollen, 1989, pp. 4-9). É também desta década o aparecimento do software LISREL (Jöreskog, 1978) para a AEE, democratizando o uso da AEE nas ciências sociais e humanas.

A maior diferença entre a AEE e as outras técnicas estatísticas multivariadas reside no facto de que com a AEE é possível estimar simultaneamente uma série de equações interdependentes, ou seja, é possível estimar simultaneamente múltiplas equações de regressão, sendo que as variáveis dependentes podem ser latentes e/ou observadas. Contudo, apesar dos SEM poderem ser testados de várias maneiras, todos eles apresentam três características essenciais que os distinguem das outras técnicas: (1) Estimam relações de dependência múltiplas e interrelacionadas, (2) Tem capacidade para representar conceitos não observáveis dessas relações e quantificar os erros de medida no processo de estimação e (3) Definem um modelo capaz de explicar todo este conjunto de relações.

3.1.1. Variáveis em AEE

O benefício da utilização de variáveis latentes:

O termo constructo ou variável latente diz respeito a um conceito não observável que pode ser representado por variáveis observáveis ou mensuráveis, denominadas de indicadores ou variáveis manifestas. No entanto, com o conhecimento adquirido através quer de perspectivas práticas como teóricas conclui-se que é impossível medir perfeitamente um conceito não observável, existindo sempre algum erro de medida que vai afectar a estimativa do verdadeiro coeficiente estrutural. O conceito teórico pode ser melhor representado por medidas múltiplas desse mesmo conceito, através da redução do erro de medida a ele associado. A utilização de indicadores para melhor aproximar o conceito latente melhora a estimação estatística das relações entre conceitos (DeVellis, Robert, 1991).

Os erros de mensuração, associados aos indicadores, constituem o maior problema quando se tenta definir um constructo latente dependente ou independente. De uma forma geral, os métodos clássicos em que as variáveis predictoras consideradas nos modelos relacionais não são isentas de erro de mensuração, têm tendência para atenuar as estimativas dos parâmetros e a inflacionar os seus erros-padrão, levando ao acréscimo dos erros estatísticos de tipo II (não concluir pela significância de uma relação que, efectivamente, existe na população) e a conclusões erróneas sobre a significância desses parâmetros (Bollen, 1989). A AEE permite ‘captar’ os erros nas variáveis por intermédio de modelos de medida e modelos estruturais que ‘descontaminam’ as variáveis dos seus erros de medida aquando da estimação dos parâmetros do modelo.

Variáveis latentes endógenas e variáveis latentes exógenas:

Tal como na análise regressão múltipla, análise múltipla discriminante e MANOVA é necessária a distinção entre variáveis dependentes e independentes, também na AEE esta distinção é importante. No entanto, devido ao facto de estarmos a trabalhar com constructos latentes, uma diferente terminologia é utilizada. Assim, os constructos exógenos equivalem às variáveis latentes independentes, uma vez que as causas destas variáveis latentes residem fora do modelo (não são explicadas por nenhuma variável latente ou manifesta no modelo). Pelo contrário, quando as causas de variação das variáveis residem no modelo, isto é, a variância destas variáveis é explicada por variáveis presentes no modelo, as variáveis dizem-se dependentes ou endógenas, e que na AEE correspondem aos constructos endógenos.

Representação gráfica do modelo:


Uma vez que os modelos de equações estruturais se podem tornar bastante complexos, os investigadores optaram por uma representação visual gráfica denominada de “diagrama de trajetórias”, onde:

- 1) Os constructos ou variáveis latentes são tipicamente representados por círculos/ovais, enquanto as variáveis de medida, manifestas ou observadas são representadas por quadrados ou rectângulos.
- 2) Para distinguir os indicadores das variáveis exógenas dos indicadores das variáveis endógenas, os primeiros são usualmente identificados como variáveis X, enquanto os segundos são normalmente identificados como variáveis Y.
- 3) As variáveis de medida X ou Y estão associadas aos seus respectivos constructos por uma seta unidireccional desde o constructo à respectiva variável mensurável ou vice-versa, consoante o modelo seja formativo ou reflexivo (ver figura 3.3).

A figura 3.1 ilustra, deste modo, diferentes situações para descrever a relação entre o constructo e os respectivos indicadores. Assim, 1(a) descreve dois tipos de relações entre variáveis latentes e observadas: a variável observada X depende de uma variável latente exógena e a variável observada Y depende de uma variável latente endógena. 1(b) descreve a relação entre múltiplas variáveis observadas (x1, x2 e X3) que dependem de uma variável latente exógena. 1(c) descreve uma relação de dependência (estrutural) entre dois constructos, e 1(d) descreve uma relação de correlação entre dois constructos. É importante salientar que a seta representa sempre a existência de uma relação e que entre os constructos são possíveis dois tipos de relações, a saber: relações de dependência e relações de correlação (covariáveis).

A especificação de relações de dependência determina automaticamente quando um constructo é considerado exógeno ou endógeno. Um constructo exógeno apenas apresenta relações de correlação com outros constructos e actua como variável independente na relação estrutural.

Figura 3.1: Diferentes tipos de relações em AEE.




Junção entre as relações de medida e relações estruturais:

Os Modelos de Equações Estruturais podem ser divididos em dois componentes principais: (1) o modelo de medida, que especifica não só o número de factores, mas também o modo como os vários indicadores estão relacionados com as variáveis latentes, e as relações entre os erros dos indicadores; e (2) o modelo estrutural, que especifica o modo como as variáveis latentes estão relacionadas umas com as outras. Considerando os dois diagramas de trajetórias representados na figura 3.2, verifica-se que, apesar dos diagramas apresentarem o mesmo conjunto de indicadores e as mesmas variáveis latentes, o primeiro diagrama (a) representa

um modelo de medida enquanto o segundo diagrama (B) representa um modelo estrutural, indicando que a relação entre a variável latente X (V.L X) e a variável latente Y (V.L Y) é inteiramente mediada pela variável latente Z (V.L Z) (representada pelas setas unidireccionais). A exacta natureza das relações é especificada no modelo estrutural; isto é, recorrendo à representação gráfica, verifica-se que a V.L X tem um efeito directo na V.L Z, a V.L Z tem um efeito directo na V.L Y e a V.L X tem um efeito directo na V.L Y. É importante salientar também que, no modelo de medida, existem três parâmetros que relacionam todas as variáveis latentes. Estes parâmetros dizem respeito às correlações entre V.L X e V.L Y, V.L Y e V.L Z e V.L X e V.L Z e são representadas por setas bidireccionais.

Figura 3.2: Diagramas de trajetória de um modelo de medida e estrutural.



Terminologia da AEE

O modelo de uma equação estrutural, conforme popularizada por Jöreskog – criador do LISREL – tem terminologia específica para o modelo estrutural e para o modelo de medida. Recorrendo à simbologia própria da representação gráfica dos modelos de equações estruturais, ilustra-se na figura 3.3 um modelo estrutural com duas variáveis latentes exógenas (ξ_1 e ξ_2) operacionalizadas por 3 variáveis manifestas independentes (x_1, x_2, x_3 e x_4, x_5, x_6); duas variáveis latentes endógenas (η_1 e η_2) operacionalizadas por 2 variáveis manifestas dependentes (y_1, y_2 e y_3, y_4).

No modelo de equações estruturais, os erros ou resíduos representam as fontes de variabilidade desconhecidas não consideradas no modelo (*i.e.*, exteriores ao modelo). Estas novas variáveis latentes explicam o comportamento das variáveis (latentes ou manifestas) do modelo que não é explicado pelas variáveis endógenas consideradas no modelo. Por exemplo, no modelo da figura 3.3, o comportamento da variável manifesta x_1 é explicado pelo factor latente ξ_1 e pelo erro δ_1 . Naturalmente, a expectativa é que, em termos médios, o erro seja nulo e que o factor latente explique a totalidade do comportamento (variância) da variável manifesta. De forma semelhante, as variáveis endógenas latentes do modelo, η_1 e η_2 , tem as suas causas em ξ_1 e ξ_2 . O comportamento de, por exemplo, η_1 que não é explicado por ξ_1 e ξ_2 , é atribuível ao erro ou *disturbance* ζ_1 . Uma outra característica do modelo de equações estruturais, que contribui para a flexibilidade dos quadros teóricos que se podem analisar com a AEE, resulta do facto de uma variável independente poder ser simultaneamente causa e efeito de outras variáveis. Como ilustra a figura 3.3, a variável η_1 influencia e é influenciada, simultaneamente, por η_2 e esta influência recíproca é ilustrada pelo símbolo (\rightleftarrows).


Tabela 3.1: As variáveis na notação LISREL

| | | | |
|---------|--------------|---------------------|--|
| ksi | ξ_i | $(i = 1, \dots, n)$ | Variáveis latentes exógenas, independentes |
| eta | η_j | $(j = 1, \dots, m)$ | Variáveis latentes endógenas, dependentes |
| zeta | ζ_j | $(j = 1, \dots, m)$ | Residuais das variáveis latentes endógenas η_j quando estas variáveis são preditas pelas variáveis latentes exógenas ξ_1, \dots, ξ_n e as variáveis latentes endógenas $\eta_1, \dots, \eta_{j-1}, \eta_{j+1}, \dots, \eta_m$ |
| x | x_k | $(k = 1, \dots, q)$ | Indicadores das variáveis latentes exógenas ξ_1, \dots, ξ_n |
| y | y_l | $(l = 1, \dots, p)$ | Indicadores das variáveis latentes endógenas η_1, \dots, η_m |
| delta | δ_k | $(k = 1, \dots, q)$ | Erros de medida, associados aos indicadores x_1, \dots, x_q das variáveis latentes exógenas |
| epsilon | ϵ_l | $(l = 1, \dots, p)$ | Erros de medida, associados aos indicadores y_1, \dots, y_p das variáveis latentes endógenas |

Tabela 3.2: Parâmetros matriciais na notação LISREL

| Matriz | Elementos | | | |
|--------|-------------------|---------------|------------------------|--|
| GA | Γ | gamma | γ_{ji} | Coeficiente estrutural do efeito da variável latente exógena ξ_i na variável latente endógena η_j |
| BE | B | beta | $\beta_{jj'}$ | Coeficiente estrutural do efeito da variável latente endógena $\eta_{j'}$ na variável latente endógena η_j |
| LX | Λ^x | lambda-x | λ_{ki}^x | Coeficiente estrutural do efeito da variável latente exógena ξ_i nas variáveis manifestas correspondentes x_k (peso factorial estandardizado de x_k em ξ_i) |
| LY | Λ^y | lambda-y | λ_{lj}^y | Coeficiente estrutural do efeito da variável latente endógena η_j nas variáveis manifestas correspondentes y_l (peso factorial estandardizado de y_l em η_j) |
| TD | Θ^δ | theta-delta | θ_{kk}^δ | Variável δ_k , corresponde à variância do erro de medida (porção da variância original do indicador x_k) |
| TE | Θ^ϵ | theta-epsilon | θ_{ll}^ϵ | Variável ϵ_l , corresponde à variância do erro de medida (porção da variância original do indicador y_l) |
| PH | Φ | phi | φ_{ii} | Variância da variável latente exógena ξ_i (elementos da diagonal da matriz de covariância Φ de todas as variáveis latentes exógenas ξ_i) |
| | | | $\varphi_{ii'}$ | Covariância das variáveis latentes exógenas ξ_i e $\xi_{i'}$ (elementos fora da diagonal da matriz de covariância Φ de todas as variáveis latentes exógenas ξ_i) |
| PS | ψ | psi | $\psi_{jj'}$ | Variância da variável residual ζ_j (porção da variância da variável latente endógena η_j que não é explicada por outras variáveis latentes) |


Figura 3.3: representação gráfica de um modelo de equações estruturais com duas variáveis latentes exógenas (ξ_1 e ξ_2) operacionalizadas por 3 variáveis manifestas independentes (x); duas variáveis latentes endógenas (η_1 e η_2) operacionalizadas por 2 variáveis manifestas dependentes (y) cada uma. Neste modelo, as variáveis latentes exógenas estão correlacionadas (ϕ_{12}), as *disturbances* (erros de variáveis latentes) associadas às variáveis latentes endógenas estão correlacionadas (ψ_{12}) assim como dois erros associados as variáveis manifestas dependentes (θ_{23}). Por convenção os índices dos pesos factoriais (λ) e dos coeficientes estruturais (γ) são representados por ordem de efeito para causa. Por exemplo, o peso factorial do factor (ξ_1) em (x_2) é (λ_{21}). De forma semelhante (γ_{12}) representa o coeficiente estrutural ou coeficiente de regressão de (ξ_2) para (η_1). Neste modelo, a ausência de setas indica que as variáveis não estão, de alguma forma, relacionadas.



Modelos reflexivos vs. Modelos formativos

O modelo de equações estruturais pertence a uma classe de modelos estatísticos ditos 'modelos reflexivos'. Nestes modelos, as variáveis latentes manifestam-se ou reflectem-se nas variáveis manifestas. Adicionalmente, assume-se que um conjunto de variáveis manifestas, que são a manifestação de uma variável latente, esta codificado na mesma direcção conceptual sendo positiva a correlação entre essas variáveis. Pelo contrário, nos modelos 'formativos', as variáveis latentes são um compósito ou são 'formadas' pelas variáveis manifestas; as variáveis manifestas podem estar positiva ou negativamente correlacionadas e não necessitam de estar codificadas na mesma dimensão conceptual. A figura 3.3 ilustra, graficamente, os dois tipos de modelos

Figura 3.4: Exemplo de um modelo 'reflexivo' (A) e de um modelo 'formativo' (B). no modelo reflexivo (A), a variável latente X (V.L X) manifesta-se através das variáveis manifestas 'A','B' e 'C'. Contudo, a variável latente X não é a única causa das variáveis 'A','B' e 'C'. As causas das variáveis manifestas não explicitadas no modelo são designadas por 'erros' ou 'resíduos', que são também variáveis latentes (i.e., não conseguimos observar os 'erros' directamente). Os erros podem estar relacionados indicando causas comuns às variáveis manifestas para além das variáveis latentes definidas explicitamente no modelo. No modelo formativo (B), a variável latente Y (V.L Y) é um compósito (e.g., a média ponderada das variáveis manifestas 'D','E' e 'F'). A variável latente Y não é, assim, uma 'verdadeira' variável latente, no sentido da definição clássica.



3.1.2. *Etapas da Análise de Equações Estruturais*

O modelo de equações estruturais é um modelo linear cuja análise exige procedimentos de cálculo relativamente complexos. Por este motivo o modelo teórico que se pretende avaliar por confrontação entre as relações inerentes ao modelo de medida e ao modelo estrutural hipotetizadas pelo modelo teórico e as relações observadas subjacentes aos dados recolhidos, deve obedecer a uma estratégia de análise bem definida e estabelecida *a priori*. Com o propósito de garantir que tanto o modelo estrutural como o modelo de medida estejam especificados de forma correta, e que os resultados sejam válidos, uma série de passos ou estágios sistemáticos devem ser seguidos. Hair Jr et al. (2010) distinguem sete estágios que todo o investigador deverá efectuar ao trabalhar com a AEE: (1) desenvolvimento de um modelo teórico; (2) construção de um diagrama de caminhos de relações causais; (3) conversão do diagrama de caminhos construído anteriormente num conjunto de modelos de medida e estruturais; (4) escolha do tipo de matriz dos dados e estimação do modelo proposto; (5) avaliação e identificação do modelo estrutural; (6) avaliação dos critérios de qualidade do ajuste e (7) interpretação e modificação do modelo teórico.

1º estágio: *elaboração de um modelo teórico.*

No primeiro estágio, desenvolvimento de um modelo teórico, o que deve guiar o investigador é a premissa de que a AEE é baseada em relações causais, onde a mudança numa variável provocará inevitavelmente mudanças noutra (s) variável (s). Aqui, é importante salientar que nenhum método estatístico, por mais robusto que seja, é capaz de transformar dados transversais (correlacionais) em dados longitudinais (causais). A causalidade da qual se fala na AEE implica, na verdade, relações causais fortes e multivariadas. Na interpretação dos dados transversais e na AEE, deve-se trabalhar com a ideia de preditor x consequência e não exactamente, causa x efeito, como nas pesquisas longitudinais (Mueler, 1997).


O investigador deverá ter um conhecimento profundo do tema para determinar que variáveis são dependentes e independentes. Esse cuidado assegurará que sejam respeitados os quatro critérios de causalidade estabelecida na AEE: (1) associação suficiente entre duas variáveis; (2) evidências anteriores de causa x efeito; (3) falta de variáveis causais alternativas e (4) uma base teórica para a relação. Hair Jr et al. (2010) reconhecem também que nem sempre é possível atender a todos os critérios, mas que frente a uma sólida perspectiva teórica, é possível fazer afirmações de causalidade. Além de possibilitar reconhecer as relações entre as variáveis para atender à causalidade, o conhecimento teórico aprofundado do tema permite que o investigador evite erros de especificação. O erro de especificação ocorre quando se omite uma variável relevante ao modelo, o que causa uma avaliação errónea da importância das demais variáveis e, por conseguinte, falta de qualidade no ajuste do modelo proposto.

2ºestágio: construção de um diagrama de caminhos de relações causais

Nesta fase, guiado pela teoria, o investigador irá designar os constructos latentes a incluir no modelo, assim como o conjunto de indicadores mensuráveis atribuídos aos mesmos. O investigador deve determinar, esquematicamente, as relações causais (preditivas) e associativas (correlações) entre as variáveis dependentes e independentes. Deve-se usar setas unidireccionais para determinar as relações causais e setas bidireccionais para determinar associações entre os constructos, e, em alguns casos, até mesmo entre os indicadores (Hair Jr et al., 2005).

Figura 3.5. Exemplo de um diagrama de caminhos

Nota: Adaptado de Hair Jr et al. (2005).




3ºestágio: conversão do diagrama de caminhos construído anteriormente num conjunto de modelos de medida e estruturais

No terceiro estágio, conversão do diagrama de caminhos construído anteriormente num conjunto de modelos estrutural e de medida, o investigador deverá definir o modelo de uma forma mais formal, nomeadamente através de equações que definem o modelo estrutural, o modelo de medida e um conjunto de matrizes indicando as correlações teorizadas entre constructos e variáveis.

Transformar um diagrama de caminhos em equações que reflectem o modelo estrutural é uma passagem directa que implica o reconhecimento dos constructos endógenos e exógenos. Os constructos endógenos formam as variáveis dependentes na equação e os constructos exógenos formam as variáveis independentes (ver figura 3.5). Para definir o modelo de medida, o investigador deverá especificar que variáveis definem cada constructo.

Figura 3.6. Exemplo da transformação de um diagrama de caminhos em equação estrutural

Nota: Adaptado de Hair Jr et al. (2005) – b é o coeficiente estrutural de cada efeito teorizado e ε é o erro que é formado pelos erros de especificação e pelos erros aleatórios de mensuração.



Finalizando os requisitos do terceiro estágio, deve-se verificar a existência de correlações entre constructos endógenos – o que é comum, representado uma influência compartilhada sobre as variáveis – ou entre os exógenos – que tem menos aplicações apropriadas e pode acarretar má interpretação das equações estruturais (Hair Jr et al., 2005).

4ºestágio: escolha do tipo de matriz dos dados e estimação do modelo proposto

No quarto estágio, escolha do tipo de matriz dos dados e estimação do modelo proposto, o investigador deverá efectuar a entrada dos dados de forma apropriada e para a selecção dos procedimentos de estimação.

Quanto à escolha do tipo de matriz de dados, na AEE, a entrada de dados de todos os indicadores do modelo poderá ser feita através da matriz de variância-covariância (as diferenças entre os métodos assentes nas escolhas das diferentes matrizes serão aprofundadas nas secções 3.2 e 3.3) ou da matriz de correlação. Originalmente, a AEE foi formulada para trabalhar com matrizes de variância-covariância. A vantagem do uso deste tipo de matriz é a possibilidade de comparar diferentes amostras e populações, na medida em que ela fornece comparações válidas para esta finalidade. Na matriz de correlação, esta possibilidade de comparações não ocorre. “O uso de correlações é adequado quando o

objectivo da pesquisa é apenas compreender o padrão de relações entre os constructos, mas não aplicar a variância total de um constructo” (Hair Jr et al., 2005, p. 484)

Estratégia para lidar com dados perdidos

É nesse estágio que o investigador vai determinar como tratar os dados perdidos. Geralmente existem quatro métodos principais para lidar com este problema (Brown, 2006). (1) – “Eliminação completa” (listwise deletion), onde todas as observações que contêm dados perdidos são eliminadas), (2) – “eliminação parcialmente completa”, (pairwise deletion), onde são utilizados todos os dados não perdidos), (3) – “técnicas de imputação” (ex: substituição dos valores perdidos pelo valor médio da variável), e (4) – “método da máxima verosimilhança directa”.

Tradicionalmente, os dois primeiros métodos foram os mais utilizados e considerados os mais adequados, no entanto, a utilização das respectivas técnicas pode trazer alguns tipos de problemas. Ambas eliminação completa e parcialmente completa, ao eliminar todas as observações que contêm dados perdidos pode provocar uma perda considerável da proporção da amostra original, provocando uma diminuição do poder estatístico, uma menor precisão das estimativas dos parâmetros, erros padrão e testes estatísticos (Allison, 2002,2003; Little & Rubin, 2002; Schafer & Graham, 2002).

Deste modo, Brown, Timothy A. (2006), sugerem a aplicação de “técnicas de imputação múltiplas” e do método de máxima verosimilhança (neste caso conhecido como o método de máxima verosimilhança directa) uma vez que, com estes métodos, todos os dados disponíveis na base de dados são utilizados. Para Hair, jr et all 2010, se os dados perdidos forem aleatórios, constituírem menos de 10% das observações e os pesos factoriais forem relativamente altos (iguais ou superiores a 0.7), então qualquer técnica pode ser considerada apropriada. Contudo, quando os dados perdidos criam problemas de maior dimensão, o investigador tem que ponderar consideravelmente sobre a forma de contornar os problemas provenientes dos dados perdidos. A tabela 3.3 mostra, deste modo, as vantagens e desvantagens de cada técnica em particular.

Tabela 3.3: vantagens e desvantagens dos métodos de tratamento de dados perdidos.

| Método | Vantagens | Desvantagens |
|---|--|---|
| Eliminação completa (listwise) | <p>1-χ^2 resulta pouco enviesado na maioria das situações.</p> <p>2-Tamanho amostral efectivo é conhecido.</p> <p>3-Fácil de implementar em qualquer software.</p> | <p>1-Aumenta a verosimilhança da não-convergência, a menos que os pesos factoriais sejam superiores a 0.6 e o tamanho amostral superior a 250.</p> <p>2-Aumenta a verosimilhança do viés dos pesos factoriais.</p> <p>3-Aumenta a verosimilhança do viés das estimativas das relações entre factores.</p> |
| Eliminação parcialmente completa (pairwise) | <p>1-Menos problemas em convergir.</p> <p>2-Estimativas dos pesos factoriais relativamente livres de viés.</p> <p>3-Fácil de implementar em qualquer software.</p> | <p>1-O χ^2 torna-se enviesado quando a quantidade de dados perdidos excede os 10%, quando os pesos factoriais são elevados e o tamanho amostral elevado.</p> |
| Máxima verosimilhança directa (MLD) | <p>1-Resoluções aplicadas directamente no processo de estimação.</p> <p>2-Na maioria das situações apresenta menor viés do que com os outros métodos.</p> | <p>1-O investigador não tem controlo sob o processo de resolução dos dados perdidos.</p> <p>2-Não há conhecimento do impacto que os dados perdidos provocam nas estimativas.</p> <p>3-Tipicamente existe apenas um subconjunto de índices de ajustamento disponíveis.</p> |
| Técnicas de imputação | <p>1-Estimativas resultam não enviesadas resultando numa melhor validação do modelo.</p> <p>2-Utiliza todos os dados disponíveis preservando o tamanho amostral e o poder estatístico.</p> <p>3-Resultados são imediatamente interpretáveis.</p> | <p>1-Considera os dados imputados como dados reais, descurando a incerteza própria dos valores imputados.</p> |

Métodos de estimação

A fase de estimação consiste na obtenção de estimativas dos parâmetros do modelo que reproduzam o melhor possível os dados observados na amostra em análise. Esta estimação é feita, normalmente, a partir das matrizes de variância-covariância das variáveis manifestas. Nesta fase é necessário recordar que, na AEE, os dados correspondem às variâncias e covariâncias das variáveis manifestas e não às observações de cada sujeito em cada variável manifesta (MAROCO, 2010). Assim, o objectivo da estimação dum modelo de equações estruturais passa por encontrar um conjunto de estimativas para os parâmetros do modelo (pesos factoriais, coeficientes de regressão, covariâncias, médias, etc..) que maximizem a probabilidade de observar a estrutura correlacional das variáveis manifestas observadas na amostra.

Por outras palavras, um método de estimação é um método utilizado para alcançar um conjunto de estimativas do modelo. Um estimador é uma estatística de interesse particular utilizada na aproximação de um parâmetro populacional (e.g., média, erro padrão, coeficiente estrutural) e uma estimativa é o actual valor produzido por um estimador proporcionado pelo respectivo método de estimação (Kline, 2011).

Vários métodos de estimação e respectivas variações têm vindo a ser desenvolvidas e aplicadas à AEE, incluindo o método da máxima verosimilhança (ML), e máxima verosimilhança com erros padrão robustos (MLR; Muthén & Muthén, 1998-2010), mínimos quadrados generalizados (GLS) e mínimos quadrados ponderados (WLS). No entanto o desempenho destes métodos podem ser fracos sobre certas condições. Especificamente, ML e MLR, tendem a perder precisão na estimação dos parâmetros perante uma amostra pequena (e.g., ML; Hoogland & Boomsma, 1998; Hu, Bentler, & Kano, 1992; Olsson, Foss, Troye, & Howell, 1999); GLS, por exemplo é ‘insensível’ á má especificação do modelo, o que leva a uma sobrevalorização das estatísticas de ajustamento (i.e., erros do tipo 1 inflacionados; Olsson, Troye, & Howell, 1999). Em resposta às limitações destes e outros métodos semelhantes, foram desenvolvidas aproximações alternativas na estimação com AEE incluindo os mínimos quadrados parciais (PLS; Wold, 1975), e a Cadeia de Markov Monte Carlo (MCMC; Hastings, 1970).

Os métodos de estimação utilizados em AEE e respectivas funções de discrepância (f) variam consoante o *software* de equações estruturais utilizado e consoante o tipo de pressupostos sobre a natureza da medida e das distribuições das variáveis. A maioria dos *softwares* de equações estruturais usa um ou mais dos métodos que a seguir se descrevem:

Método da máxima verosimilhança (ML)

O método tradicional, e mais utilizado na AEE, é o método da máxima verosimilhança. Este método estima os parâmetros que maximizam a verosimilhança de observar a matriz S . A função de discrepância de máxima verosimilhança que o algoritmo minimiza é (Jöreskog & Sörbom, 1996)

$$f_{ml} = \log|\Sigma(\hat{\theta})| + \text{tr}(S\Sigma(\hat{\theta})^{-1}) - \log|S| - (p + q) \quad (3.1)$$

onde $|\dots|$ representa a função determinante de uma matriz e $\text{tr}(\dots)$ representa a função traço de uma matriz. Se o modelo exigir a estimação das médias das variáveis, a função de discrepância de ML é (Arbuckle, 2008):

$$f_{ML} = \log|\Sigma(\hat{\theta})| + \text{tr}(S\Sigma(\hat{\theta})^{-1}) - \log|S| - (p + q) + [\bar{x} - \mu(\hat{\theta})]'\Sigma(\hat{\theta})^{-1}[\bar{x} - \mu(\hat{\theta})] \quad (3.2)$$

Onde \bar{x} representa o vector das médias das variáveis manifestas e μ (λ) representa o vector das médias estimadas pelo modelo teórico em análise. O método ML produz estimativas dos parâmetros centradas e consistentes, isto é, à medida que a dimensão da amostra (n) aumenta, as estimativas aproximam-se do verdadeiro valor do parâmetro populacional, com distribuição normal. Contudo, estas propriedades só são válidas quando as variáveis manifestas apresentam distribuição normal multivariada, ou quando a matriz de covariâncias apresenta distribuição de Wishart (Arbuckle, 2008; Blunch, 2008). De uma forma geral, o método ML é robusto à violação de pressupostos de normalidade se a assimetria e achatamento das distribuições das variáveis manifestas não forem muito grandes.

ML é tipicamente o método de estimação preferido dentro da AEE. Quando os seus pressupostos são verificados, as estimativas dos parâmetros resultam não enviesadas, consistentes e eficientes (Bollen, 1989). Apesar do consenso literário vincando a importância destes pressupostos, as consequências da violação aos mesmos parecem não ser entendidas completamente pela maioria dos investigadores que utilizam este método, e por isso, ML é frequentemente aplicado em circunstâncias onde estes pressupostos são violados dando origem a erros padrão elevados e estimativas paramétricas enviesadas (i.e, consistentemente

sobrestimadas e subestimadas), mesmo até quando o modelo é correctamente especificado (Gerbing & Anderson, 1985; Hwang et al., 2010). Por um lado, ML é uma ferramenta poderosa quando é utilizada correctamente, e alguma investigação tem vindo a mostrar que este método é robusto a algumas violações dos pressupostos (e.g., Babakus, Ferguson, & Jöreskog, 1987; Maas & Hox, 2004). Por outro lado, a justa restrição aos pressupostos imposta pelo método da ML fazem dele o método de estimação apropriado quando é utilizado no contexto de dados reais caracterizados por amostras pequenas, modelo populacionais desconhecidos e outras condições não ideais.

Especificamente, ML assenta na teoria assintótica que implica amostras grandes, uma correcta especificação do modelo, observações independentes, variáveis exógenas independentes (i.e, os valores obtidos para as variáveis exógenas devem ser independentes), e que a distribuição condicional dos scores das variáveis endógenas na população apresente distribuição normal multivariada (Kline, 2011). Uma amostra pequena é problemática no contexto de ML uma vez que as estimativas e testes de ajustamento resultantes não são assintoticamente verdadeiros (Lee & Song, 2004). Isto significa que, sem amostras de maior dimensão, a validade das inferências estatísticas devem ser questionadas. ML é conhecido por ser robusto a violações menores aos seus pressupostos, no entanto a extensão dessa robustez varia de acordo com os dados e com o modelo.

Mínimos quadrados não ponderados (ULS)

O método dos mínimos quadrados não ponderados é um método iterativo que estima os parâmetros do modelo que minimizam a soma dos quadrados dos erros que são os elementos da matriz residual (E) dada por:

$$E = S - \Sigma(\hat{\theta}) \quad (3.3)$$

a função de discrepância a minimizar é (Bollen, 1989; Jöreskog & Sörbom, 1996)

$$f_{ULS} = \frac{1}{2} \text{tr}[(S - \Sigma(\hat{\theta}))^2] \quad (3.4)$$

O algoritmo minimiza metade da soma dos elementos diagonais de E, o que é equivalente a minimizar a soma de quadrados dos erros (SQE). O método ULS não tem assunções (à semelhança do método dos mínimos quadrados da regressão linear), é consistente, mas não assintoticamente eficiente (i.e., a variância das estimativas não diminui à medida que n aumenta).

Mínimos quadrados generalizados (GLS)

O método dos mínimos quadrados generalizados é um método iterativo que estima os parâmetros ponderando os erros de estimação da matriz E, com pesos correspondentes ao inverso da matriz de covariância amostral. Assim, os elementos da matriz E que tem maior variância amostral têm menor peso no modelo. Desta forma, obtém se estimativas mais eficientes (com menor variância) do que as que se obteriam se as observações não fossem ponderadas. A função de discrepância a minimizar é (Arbuckle,2008; Jöreskog & Sörbom,1996)

$$f_{GLS} = \frac{1}{2} tr[S^{-1} (S - \Sigma(\hat{\theta}))]^2 = \frac{1}{2} tr[(I - S^{-1}\Sigma(\hat{\theta}))^2] \quad (3.5)$$

o que é equivalente a minimizar a *SQE* ponderada pelo inverso da matriz de covariância amostral (à semelhança do método dos mínimos quadrados ponderados da regressão linear). O método GLS tem as mesmas propriedades assintóticas que o método ML (consistência e eficiência) produzindo estimativas com distribuição normal assintótica (Bollen,1989). Este método permite obter estatísticas de teste para o ajustamento global, tal como o método ML.

O método GLS pode ser utilizado com suposições menos restritivas sobre a normalidade das variáveis do que o método ML (Blunch,2008). Contudo, o método GLS tem associadas maiores probabilidades de erro do tipo 1 no teste do qui quadrado à qualidade global do ajustamento e produz estimativas dos parâmetros mais vezes incorrectas do que o método de ML (Olsson, Troye, & nHowell,1999). Por este motivo, o método GLS é, geralmente, menos utilizado do que o ML.

Distribuição assintótica livre (ADF) ou Mínimos Quadrados Ponderados (WLS)

O método de distribuição assintótica livre, como o nome indica, não exige que as variáveis manifestas apresentem normalidade multivariada. Por este motivo, o método ADF ou WLS apresenta alguma atractividade para as aplicações das ciências sociais e humanas onde, com frequência, não é possível verificar o pressuposto da normalidade multivariada. A função de discrepância que o algoritmo iterativo minimiza é (Arbuckle, 2008; Jöreskog & Sörbom, 1996)

$$f_{ADF} = (s - \sigma(\hat{\theta})) W^{-1} (s - \sigma(\hat{\theta})) \sigma(\hat{\theta}) \quad (3.6)$$

onde $s'=[s_{11} \ s_{21} \ s_{22} \ \dots \ s_{kk}]$ é o vector de elementos da matriz triangular inferior S incluindo a diagonal; σ corresponde ao vector de elementos da matriz triangular inferior Σ () incluindo a diagonal; \mathbf{W} é uma matriz de distâncias de todas as observações às médias de todas as variáveis, cujo elemento genérico é:

$$[\mathbf{W}]_{ij,kl} = w_{ij,kl} - w_{ij}w_{kl}$$

$$w_{ij} = \frac{1}{n} \sum_{r=1}^n (x_{ir} - \bar{x}_i) (x_{jr} - \bar{x}_j)$$

$$w_{ij,kl} = \frac{1}{n} \sum_{r=1}^n (x_{ir} - \bar{x}_i) (x_{jr} - \bar{x}_j) (x_{kr} - \bar{x}_k) (x_{lr} - \bar{x}_l) \quad (3.7)$$

a matriz \mathbf{W}^{-1} na função de discrepância corrige o achatamento das variáveis manifestas. A função de discrepância ADF permite obter estatísticas de teste à qualidade global do modelo com distribuição assintótica χ^2 e erros padrão dos parâmetros não enviesados. Contudo, e apesar da atractividade teórica do método, o cálculo da matriz \mathbf{W} é relativamente complexo uma vez que a sua dimensão aumenta exponencialmente em função do número de variáveis manifestas do modelo. A matriz \mathbf{W} tem de ser uma matriz invertível (ser positiva e definida) (Bollen,1989).

Mesmo um modelo simples com apenas 10 variáveis produz uma matriz \mathbf{W} com 55 linhas e 55 colunas que é necessário inverter. Este facto, exige amostras de dimensão muito elevada ($n > 1000$) de forma a evitar problemas de convergência numerosa e de singularidade. Por outro lado, a estimativa dos momentos de ordem 4 com precisão razoável requer também amostras com dimensão de ordem dos milhares. Finalmente o método não lida de forma eficiente com observações omissas (Jöreskog & Sörbom,1996).

Se a dimensão da amostra não for suficiente para o método ADF e não for desejável assumir a validade da distribuição (aproximadamente) normal das variáveis manifestas exigida pelo método ML, alguns *softwares* permitem a utilização de métodos bootstrap nos quais as distribuições empíricas são deduzidas por reamostragem de amostra original.

5º estágio: avaliação e identificação do modelo estrutural

No quinto estágio – avaliação e identificação do modelo estrutural, a questão central reside na identificação do modelo. Segundo Hoyle (1995), “a identificação diz respeito à correspondência entre a informação a ser estimada – os parâmetros livres – e a informação da qual será estimada – variâncias e covariâncias observadas” (p.4). Ullman (2001) fornece um exemplo simples que explica a questão da identificação do modelo:

- *Um modelo é dito identificado quando há apenas uma solução numérica para cada parâmetro no modelo. Por exemplo, tenhamos a variância $Y=10$ e a variância $Y=\alpha+\beta$. Quaisquer valores podem ser substituídos por α e β desde que somem 10. Não há uma solução única nem para α e nem para β ; posto isto, há um infinito número de combinações entre os dois números que podem resultar em 10. Dessa forma, esta equação simples não está identificada. Entretanto, se fixássemos o valor de α como 0, então haveria uma única solução para β , 10, e a equação estaria identificada (p.691).*

Para Schumacker e Lomax (2004), a identificação do modelo depende da designação dos parâmetros como livres, fixos e condicionados. Após a especificação do modelo e as especificações dos parâmetros determinadas, os parâmetros são combinados para formar uma, e apenas uma matriz de variância-covariância (Σ).

Hair Jr et al. (2005) afirmam que para fins de identificação, o investigador deve preocupar-se em primeiro lugar, com a diferença entre o tamanho relativo da matriz de covariância - ou de correlação - em relação ao número de coeficientes estimados. Esta diferença é denominada de graus de liberdade, que é calculada como:

$$df = \frac{1}{2} [(p+q)(p+q+1)] - t \quad (3.8)$$


onde: df = graus de liberdade; p = número de indicadores endógenos; q = número de indicadores exógenos e t = número de coeficientes estimados no modelo proposto

Tradicionalmente, existem três níveis de identificação dos modelos (Hair Jr et al., 2005, Schumacker & Lomax, 2004):

Sub-identificado:

Um modelo é dito sub-identificado, quando o número de parâmetros a estimar excede o número de elementos informativos que constituem a matriz de variância-covariância, ou seja, nesse tipo de modelos, o número de parâmetros a estimar é superior a informação presente nas variáveis manifestas (variâncias e covariâncias) sendo os graus de liberdade destes modelos inferiores a 0.

Figura 3.7: modelo factorial confirmatório sub-identificado.




A figura 3.6 mostra um exemplo de um modelo factorial confirmatório sub-identificado. Como se pode verificar, existem 4 parâmetros a estimar (que correspondem aos dois pesos factoriais e aos dois erros), contudo, a matriz de variância-covariância é composta apenas pelas duas variâncias correspondentes às duas variáveis, e a uma única covariância proveniente da relação entre as duas, resultando num total de 3 peças informativas. Num modelo desta natureza, não existe uma única solução possível pois existe um número infinito de parâmetros que se podem ajustar bem aos dados.

Exactamente identificado:

Um modelo é dito exactamente identificado, quando o número de parâmetros a estimar iguala o número de elementos informativos que constituem a matriz de variância-covariância. Isto pode ser constatado na figura 3.7.

Figura 3.8: modelo factorial confirmatório exactamente identificado.




Nesta situação, o modelo tem zero graus de liberdade uma vez que $[3(3+1)/2] - 6 = 0$. Isto significa que toda a informação é utilizada, e consequentemente, haverá apenas um conjunto de parâmetros (uma solução) que reproduz perfeitamente a matriz de variância covariância, resultando num ajustamento perfeito.

Sobre identificado:

Do mesmo modo, um modelo é dito sobre identificado, quando o número de elementos informativos que constituem a matriz de variância-covariância é superior ao número de parâmetros a estimar. Neste caso, o modelo apresenta um número positivo de graus de liberdade, e que vão ser utilizados nos índices descritivos de ajustamento. Como se pode ver na figura 3.8, um modelo de medida unidimensional com quatro indicadores já produz um constructo sobre identificado e para o qual se pode calcular um valor de ajuste.

Figura 3.9: modelo factorial confirmatório sobre identificado.



Em suma, para uma boa identificação do modelo Hair Jr et al. (2005) propõem três acções correctivas: (1) o número de peças informativas deve igualar ou exceder o numero de parâmetros a estimar, (2) devem ser evitados constructos com três indicadores, excepto se existirem mais constructos no modelo possuindo mais de três indicadores, (3) no caso de modelos que contenham dois ou mais factores, e dois indicadores por cada constructo, a solução será sobre identificada, mostrando que toda a variável latente está correlacionada com pelo menos uma outra variável latente e que os erros entre os indicadores são não correlacionados.

Existem várias regras, com diferentes graus de complexidade (e de difícil determinação manual) para avaliar a identificação de um modelo. Felizmente, a maioria dos *softwares* avaliam a identificação do modelo e identificam os parâmetros responsáveis pela não identificação do modelo, caso ela exista. Algumas estratégias para lidar com a indeterminação do modelo podem incluir uma ou mais das opções seguintes (eg., Bollen, 1989):

- a) Regra-t: Esta regra é aplicada na parte estrutural do modelo e é uma condição necessária, mas não suficiente para a identificação. Ela estabelece que o modelo deve ter mais informações (variáveis) conhecidas do que parâmetros a serem estimados, isto é, o número de elementos não redundantes da matriz de covariância ou de correlações das variáveis observadas deve ser maior ou igual ao número de parâmetros livres em θ a serem estimados. Se esta condição for satisfeita então o modelo poderá ser (mas não necessariamente) identificado. Do contrário, será não-identificado.

A equação da regra é a seguinte:

$$t \leq \frac{1}{2} (p + q)(p + q + 1) \quad (3.9)$$

Onde $(p+q)$ é o número de variáveis observadas e t é o número de parâmetros livres em θ a serem estimados.

- b) Fixar pelo menos um dos coeficientes pela variável latente e as suas variáveis manifestas de forma a indicar qual a métrica da variável latente.
- c) Fixar a variância de uma ou mais variáveis latentes (estandardizar as variáveis latentes)
- d) Ter pelo menos 3-4 variáveis manifestas por variável latente. Menos de 3 variáveis manifestas por variável latente pode provocar também problemas de fiabilidade psicométrica.
- e) Simplificar o modelo igualando trajetórias entre si: usar testes à igualdade de parâmetros e/ou eliminar trajetórias de feedback.
- f) Fixar parâmetros (ex: coeficientes de trajetória, pesos factoriais) cuja magnitude é conhecida (teoria).
- g) Simplificar o modelo reduzindo o número de variáveis latentes; eliminando variáveis manifestas multicolineares; fixando trajetórias em 0 (ou seja, eliminar trajetórias) e/ou aumentando a dimensão da amostra.

- h) Caso existam valores perdidos, usar um método de eliminação completa de dados perdidos (não usar métodos de eliminação parcial) ou utilizar métodos de imputação de dados perdidos (eg., substituição pela média).
- i) Aumentar o número de iterações ou usar um outro método de estimação que não a máxima verosimilhança (o método na maioria dos softwares).

6º estágio: avaliação dos critérios de qualidade do ajuste

O sexto e penúltimo estágio que corresponde à avaliação dos critérios de qualidade do ajuste e deve ser iniciado com a identificação de estimativas transgressoras. Os casos de estimativas transgressoras mais comuns são: (1) variáveis Heywood - variáveis com variância negativa; (2) coeficientes padronizados excedentes ou muito próximos a 1; e, (3) erros padrão elevados. Caso as encontre, o investigador deverá primeiramente resolvê-las, com as mesmas estratégias para resolver os problemas de identificação, antes de analisar os demais resultados do modelo (Hair Jr et al., 2005).

Após a correção das estimativas transgressoras, o investigador deverá avaliar o ajuste geral do modelo onde o principal objectivo passa por estabelecer níveis/medidas aceitáveis de ajustamento para o modelo de medida. Uma vez que o ajustamento se refere à semelhança entre a matriz de covariâncias observada e a matriz de covariâncias esperada, a avaliação da qualidade do modelo pode ser realizada com (1) testes de ajustamento, (2) índices empíricos que se baseiam nas funções de verosimilhança ou na matriz dos resíduos obtidos durante o ajustamento do modelo, ou (3) com a análise de resíduos e da significância dos parâmetros (Anderson, Babin, Black & Hair, 2010).

Teste de ajustamento χ^2

Este índice pertence às medidas de ajuste absoluto e é sem dúvida a medida mais utilizada quando se deseja comparar as diferenças entre as duas matrizes de covariância (matriz de covariância esperada e observada).

Esta medida é tanto menor quanto maiores são as semelhanças entre as duas matrizes, por isso o valor 0 representa o valor óptimo pois significa que não existem quaisquer diferenças entre elas, corroborando deste modo a hipótese nula que apoia a igualdade de matrizes. Contudo, existem dois problemas que tornam esta medida um pouco vulnerável. Com efeito, a estatística de qui quadrado aumenta com o aumento do tamanho amostral, ou seja, embora as diferenças entre as matrizes sejam iguais, o facto do tamanho amostral aumentar leva automaticamente a um incremento da estatística χ^2 , criando aqui um paradoxo na medida em que estatisticamente são desejáveis amostras de grande dimensão.

Por outro lado, esta estatística tem também tendência a aumentar à medida que número de indicadores no modelo vai sendo maior, causando dificuldades em encontrar um bom ajuste. Principalmente por estas duas razões, o χ^2 é sempre acompanhado de outras medidas de ajustamento que suavizem o enviesamento proveniente de amostras grandes e da complexidade do modelo.

O teste do χ^2 de Ajustamento é um teste à significância da função da discrepância

$$f = F(S - \Sigma(\hat{\theta})) \quad (3.10)$$

minimizada durante o ajustamento do modelo. As hipóteses estatísticas do teste são:

$$H_0: \Sigma = \Sigma(\hat{\theta}) \text{ (a matriz de covariância populacional é igual à matriz de covariância estimada pelo modelo)}$$

Vs.

$$H_1: \Sigma \neq \Sigma(\hat{\theta}) \text{ (a matriz de covariância populacional é diferente da matriz de covariância estimada pelo modelo)}$$

As hipóteses do teste também podem ser escritas em função da matriz dos resíduos (3.3) como $H_0: E = 0$ vs. $H_1: E \neq 0$. A estatística de teste é (Bollen, 1989, p.263; Jöreskog & Sörbom, 1996, p.28):

$$\chi^2 = (n - 1)f_{min} \sim \chi^2(g.l) \quad (3.11)$$

Onde f_{min} é o valor mínimo de uma das funções de discrepância para o método $ML(3.1)$, $GLS(3.5)$ ou $WLS(3.6)$ respectivamente.

Índices de qualidade de ajustamento

Os problemas associados ao teste do qui quadrado (um teste à mediocridade do ajustamento) que testa, se o ajustamento é perfeito, levou á criação de várias outras medidas de qualidade/mediocridade do ajustamento. Deste modo, de acordo com (Hair Jr et al., 2010), constituíram-se três grupos de medidas, a saber:

- 1) *Medidas de ajuste absoluto*, que são consideradas como medidas de ajuste directo, uma vez que reflectem a relação entre o modelo ajustado e os dados observados, sem qualquer comparação com outro modelo, permanecendo com um carácter independente. O próprio χ^2 é um exemplo de um índice de ajuste absoluto.

Para além deste, existem também: (1) *Standardize Root Mean Square Residual* (SRMR), que pode ser visto como a discrepância média entre as correlações observadas da matriz introduzida e as correlações previstas pelo modelo. Outro índice similar, designado (2) *Root Mean Square Residual* (RMR) reproduz a discrepância média entre as covariâncias observadas e previstas, por outras palavras, este índice corresponde à raiz quadrada da matriz dos erros dividida pelos graus de liberdade, assumindo que o modelo ajustado é o correcto (Jöreskog & Sörbom,1996):

$$RMR = \sqrt{\frac{\sum_{i=1}^{p+q} \sum_{j=1}^i (s_{ij} - \sigma(\hat{\theta}))^2}{(p+q)(p+q+1)/2}} \quad (3.12)$$

Não obstante o índice SRMR é preferível ao RMR uma vez que o segundo pode ser difícil de interpretar devido à métrica das variáveis. O SRMR pode ser calculado somando o quadrado dos elementos da matriz de correlação residual e dividindo esta soma pelo número de elementos existentes na matriz, e posteriormente aplicar a raiz quadrada a esse resultado. O valor deste índice pode variar entre 0 e 1, onde o valor 0 representa um ajuste perfeito. (3) Índice de bondade de ajustamento (GFI): O GFI foi um dos primeiros índices criados para os métodos de ML e ULS (Jöreskog & Sörbom,1996) e generalizado por Tanaka e Huba (1985) para os outros métodos:

$$GFI = 1 - \frac{(s - \sigma(\hat{\theta}))' W^{-1} (s - \sigma(\hat{\theta}))}{s' W^{-1} s} \quad (3.13)$$

O numerador é o mínimo da função de discrepância generalizada depois do modelo ter sido ajustado; o denominador é a função de discrepância antes de qualquer modelo ser ajustado. Assim, o GFI explica a proporção da covariância, observada entre

as variáveis manifestas, explicada pelo modelo ajustado (um conceito semelhante ao R^2 da regressão linear).

- 2) *Medidas de ajuste incremental/ Índices Relativos*: estes índices diferem dos primeiros na medida em que comparam o modelo estimado com um modelo base designado de modelo nulo, o qual assume que todas as variáveis são não correlacionadas. Exemplos de índices de ajuste incremental são: (1) *Normed Fit Index* (NFI): O NFI, proposto por Bentler e Bonett (1980) avalia a percentagem de incremento na qualidade do ajustamento do modelo ajustado (χ^2) relativamente ao modelo de independência total ou modelo nulo

$$NFI = 1 - X^2/X_b^2 \quad (3.14)$$

O NFI toma valores entre 0 e 1 e é tanto mais elevado quanto maior for o número de variáveis no modelo e a dimensão da amostra. Adicionalmente, para amostras de reduzida dimensão, apresenta um comportamento errático nos diferentes métodos de estimação (Hu & Bentler, 1999). Por estes motivos, o NFI é cada vez menos utilizado. (2) *Comparative Fit Index* (CFI): O CFI foi proposto por Bentler (1990) para corrigir a subestimação que ocorre, geralmente, quando se usa o NFI com amostras pequenas.

$$CFI = 1 - \frac{\max(X^2 - gl, 0)}{\max(X_b^2 - gl_b, 0)} \quad (3.15)$$

Onde χ^2 representa o valor do χ^2 do modelo alvo (o modelo que está sob avaliação), gl representam os graus de liberdade do modelo alvo, χ_b^2 é o valor do χ^2 do modelo base (modelo nulo) e gl_b representa os graus de liberdade do modelo base. Os valores do CFI podem variar entre 0 e 1, mas ao contrário do RMSR, neste caso é o valor 1 que representa um ajuste perfeito. (3) *Tucker-Lewis index* (TLI): este índice, também conhecido por *non-normed fit index* (NNFI) inclui uma função penalizadora por cada parâmetro livre estimado cujo impacto não melhore o ajustamento do modelo. Este índice pode ser calculado por:

$$TLI = \frac{\frac{X_b^2}{gl_b} - \frac{X^2}{gl}}{\frac{X_b^2}{gl_b} - 1} \quad (3.16)$$

Onde o χ^2 corresponde ao valor do χ^2 do modelo alvo, gl são os graus de liberdade do modelo alvo, χ^2_b é o valor do χ^2 do modelo base e o gl_b são os graus de liberdade do modelo base. Ao contrário do CFI, os valores deste índice podem tomar valores fora do intervalo 0-1, contudo, a interpretação continua a ser a mesma na medida em que valores próximos de 1 constituem um bom ajustamento.

- 3) *Índices de ajuste parcimonioso*: Este tipo de índices selecciona um modelo de entre vários, de acordo com a relação entre o grau de ajustamento e a complexidade do modelo. O objectivo dos índices de parcimónia é compensar a melhoria artificial do modelo que se consegue, simplesmente, por inclusão de mais parâmetros livres aproximando o modelo sob estudo ao modelo saturado. Um modelo mais complexo pode ter melhor ajustamento do que um modelo mais simples (parcimonioso) mas não ser generalizável a outras amostras (Mulaik et al., 1989). Alguns dos principais índices de parcimónia são: (1) *Parsimony CFI* (PCFI): Penaliza o CFI pelo rácio de parcimónia:

$$PCFI = CFI \times gl/gl_b \quad (3.17)$$

- (2) *Parsimony GFI* (PGFI): penaliza o GFI pelo rácio da parcimónia

$$PGFI = GFI \times gl/gl_b \quad (3.18)$$

- (3) *Parsimony NFI* (PNFI): penaliza o NFI pelo rácio de parcimónia:

$$PNFI = NFI \times gl/gl_b \quad (3.19)$$

Os valores de referência, indicadores de um bom ajustamento, para os índices de parcimónia são inferiores aos dos correspondentes índices relativos (sem penalização). De uma forma geral, considera-se que valores dos índices de parcimónia inferiores ou iguais a 0.6 indicam um mau ajustamento (Mulaik, et al., 1989); valores no intervalo] 0.6;0.8] indicam um ajustamento razoável; valores superiores a 0.8 são indicadores de um bom ajustamento (Blunch,2008).

- 4) *Índices de discrepância populacional*: estes índices comparam o ajustamento do modelo obtido com os momentos amostrais (médias e variâncias amostrais) relativamente ao ajustamento do modelo que se obteria com os momentos populacionais (médias e variâncias populacionais) (Steiger, Shapiro, & Browne, 1985). Os índices de discrepância populacional avaliam se o modelo ajustado é “aproximadamente” correcto (em oposição ao 100% correcto do teste do χ^2) comparando o ajustamento obtido na amostra com o ajustamento que se obteria se o mínimo da função de discrepância fosse obtido a partir dos momentos populacionais.
- (1) Parâmetro de não centralidade (NCP): O NCP estima quão afastado está o valor esperado da estatística χ^2 . O parâmetro de não-centralidade é estimado por (Steiger, et al., 1985)

$$NCP = \max[X^2 - gl, 0] \quad (3.20)$$

Quando o ajuste do modelo é perfeito, $NCP = 0$ e a distribuição χ^2 central permanece a mesma. Quando o ajuste do modelo não é perfeito o valor do NCP é superior a 0 e o valor esperado da distribuição desloca-se para a direita do correspondente valor central de χ^2 .

(2) *Root Mean Square Error of Approximation* (RMSEA): este é o índice mais utilizado e recomendado nesta categoria. Este índice assenta na distribuição χ^2 não central, referente á distribuição da função de ajustamento, quando o ajustamento do modelo não é perfeito. A distribuição χ^2 não central é acompanhada de um parâmetro não central (NCP), que expressa o grau de ruído do modelo. O NCP resulta de $\chi^2 - df$ (caso resultado seja negativo $NCP = 0$). Deste modo, o RMSEA é um índice de “aproximação por erro” pois avalia o quão razoavelmente bem, o modelo se ajusta à população em vez de avaliar se o modelo se coaduna exactamente com a população. Este índice pode ser calculado por:

$$RMSEA = \sqrt{F_0/gl} \quad (3.21)$$

onde gl corresponde aos graus de liberdade do modelo e d a discrepância no ajustamento por cada grau de liberdade no modelo, tornando-se o RMSEA, deste modo, sensível aos parâmetros do modelo mas insensível ao tamanho amostral. Tal como o SRMR, o valor 0 no RMSEA indica um ajuste perfeito.

- 5) *Índices baseados na teoria da informação*: estes índices são baseados na estatística χ^2 e penalizam o modelo em função da sua complexidade. Outro aspecto que é importante referir, é o facto de que os índices baseados na teoria da informação não

apresentam valores referenciais para classificar o ajustamento do modelo, sendo, o melhor modelo aquele que apresentar os menores valores em um ou mais destes índices. Alguns dos índices mais utilizados são: (1) Akaike Information Criterion (AIC): o critério de informação Akaike é dado por (Arbuckle, 2008):

$$AIC = X^2 + 2t \quad (3.22)$$

Onde t corresponde ao número de parâmetros estimados no modelo. (2) Browne-Cudeck Criterion (BCC): o critério Brown-Cudeck (Arbuckle, 2008) é:

$$BCC = X^2 + 2t \frac{(n-1)[(p+q)(p+q+3)]}{\frac{n-(p+q)-2}{(p+q)(p+q+3)}} \quad (3.23)$$

Onde p e q são respectivamente, o número de variáveis dependentes e independentes exógenas do modelo. Comparativamente ao AIC, o BCC penaliza mais modelos complexos. (3) Bayes Information Criterion (BIC). O critério de informação de Bayes é dado por: O BIC penaliza mais os modelos complexos do que o AIC ou o BC. Assim, o BIC tende a favorecer modelos mais simples do que o AIC ou o BCC. A tabela seguinte representa deste modo, um resumo dos diversos índices de ajustamento acompanhados pelo valor do ponto de corte adequado.

Ainda assim é importante realçar que nenhum destes valores pode ser considerado como valor determinante na escolha de um modelo uma vez que estes índices de ajustamento devem ser interpretados à luz das características da pesquisa (Hair Jr et al., 2010). Deste modo, segundo Pugesek, a selecção do índice deve assentar com base no propósito do modelo, ou seja, se é um modelo apenas para uso preditivo o índice mais adequado será o índice de validação cruzada, enquanto se o modelo tem como objectivo o estabelecimento de relações causa-efeito, o índice apropriado será o RMSEA (Pugesek et al 2003).

Em suma, existem três tipos de medidas de ajuste gerais do modelo: (1) medidas de ajuste absoluto, que indicam o ajuste geral do modelo; (2) medidas de ajuste incremental, que comparam o modelo proposto ao modelo nulo – aquele que é ponto de referência ou padrão de comparação – e (3) medidas de ajuste parcimonioso, que compara o ajuste do modelo aos parâmetros estimados necessários para alcançar um nível específico de ajuste (Hair Jr et al., 2005, Schumacker & Lomax, 2004; Ullman, 2001). A tabela 3.4 apresenta os índices de qualidade de ajustamento, com respectivos valores de referência, utilizados com maior frequência em aplicações de AEE.

Tabela 3.4. Medidas de Ajuste Geral do Modelo *

| | Medida | Valor aceitável |
|--------------------------------|---|---|
| Medidas de ajuste absoluto | Qui-quadrado (χ^2) | Valores menores resultam em maiores níveis de significância: a matriz verdadeira não é estatisticamente diferente da prevista |
| | Parâmetro de não centralidade (NCP) | Valores mais perto de zero são melhores. |
| | Índice de qualidade do ajuste (GFI) | Varia de zero (ajuste nulo) a 1 (ajuste perfeito) |
| | Raiz do resíduo quadrático médio (RMSR) | Valores inferiores a 0,10 |
| | Raiz do erro quadrático médio de aproximação (RMSEA) | Valores inferiores a 0,08 |
| Medidas de ajuste incremental | Índice ajustado de qualidade do ajuste (AGFI) | Varia de zero (ajuste nulo) a 1 (ajuste perfeito), recomenda-se acima de 0,90 |
| | Índice de Tucker-Lewis (TLI) ou Índice de ajuste não-ponderado (NNFI) | Varia de zero (ajuste nulo) a 1 (ajuste perfeito), recomenda-se acima de 0,90 |
| | Índice de ajuste ponderado (NFI) | Varia de zero (ajuste nulo) a 1 (ajuste perfeito), recomenda-se acima de 0,90 |
| | Índice de ajuste comparativo (CFI) | Varia de zero (ajuste nulo) a 1 (ajuste perfeito) |
| Medidas de ajuste parcimonioso | Índice de ajuste incremental (IFI) | Varia de zero (ajuste nulo) a 1 (ajuste perfeito) |
| | Índice de ajuste relativo (RFI) | Varia de zero (ajuste nulo) a 1 (ajuste perfeito) |
| | Critério de informação Akaike (AIC) | Varia de zero (ajuste perfeito) a um valores negativos (ajuste nulo) |
| | Qui-quadrado ponderado | Valores inferiores a 1 indicam um ajuste pobre; valores acima de 5 indicam necessidade de ajuste. O valor aceitável deve ser igual ou menor a 5 |

Nota: Adaptado de Hair Jr et al. (2005).

Após a análise dos ajustes globais, o investigador deve ter em atenção os ajustes específicos do modelo de medida e do modelo estrutural, nomeadamente o no que se refere à fiabilidade e validade dos instrumentos de medida.

Fiabilidade

A fiabilidade de um instrumento refere-se à propriedade de consistência e reprodutibilidade da medida. Um instrumento diz-se ‘fiável’ se mede, de forma consistente e reprodutível, uma determinada característica ou factor de interesse (Anderson, Babin, Black & Hair, 2010). Num modelo reflexivo, é assumido que o conjunto formado pelas variáveis manifestas que compõem uma determinada variável latente meça um único conceito subjacente. Cada variável manifesta reflecte (é um efeito de) a variável latente correspondente e desempenha um papel de variável endógena no conjunto específico do modelo de medida. No modelo de medida reflexivo, os indicadores ligados à mesma variável latente devem covariar: mudanças num indicador, implica mudanças nos outros indicadores. Isto implica que a consistência interna deva ser verificada, i.e. cada conjunto é assumido como sendo homogéneo e unidimensional. É importante ter a noção que num modelo reflexivo cada variável manifesta está relacionada com a variável latente correspondente através de um modelo de regressão simples:

$$x_{pq} = \lambda_{p0} + \lambda_{pq}\xi_q + \epsilon_{pq} \quad (3.24)$$

Onde λ_{pq} é o peso factorial associado à variável manifesta p -th no conjunto q -th, e o erro ϵ_{pq} representa a imprecisão no processo de medida. Os pesos factoriais estandardizados são frequentemente preferíveis para propósitos interpretativos uma vez que estes representam as correlações entre cada variável manifesta e a variável latente correspondente.

A unidimensionalidade, sendo definida como sendo a “característica de um conjunto de indicadores que tem apenas um traço inerente ou conceito em comum” (Hair Jr et al., 2005, p.470), constitui, de acordo com este autor, uma premissa para a fiabilidade de um constructo. Avaliar a unidimensionalidade consiste então, em verificar se os indicadores estabelecidos representam de fato um único constructo. Para tal é possível recorrer a três índices: 1) alfa de Cronbach; 2) o rho de Dillon-Goldstein e 3) Análise de componentes principais de um conjunto.

- a) Alfa de *Cronbach*: é um índice clássico na análise da fiabilidade e é uma medida tradicional de consistência interna no que diz respeito à AEE. Um conjunto é considerado homogéneo se o valor deste índice for superior a 0.7. de entre várias formas equivalentes e alternativas este índice pode ser expresso como (Cronbach,1951):

$$\alpha = \frac{\sum_{p \neq p'} \text{corr}(x_{pq}, x_{p'q})}{P_q + \sum_{p \neq p'} \text{corr}(x_{pq}, x_{p'q})} \times \frac{P_q}{P_q - 1} \quad (3.25)$$

Onde P_q é o número de variáveis manifestas no conjunto q -th.

- b) *Rho de Dillon-Goldstein* (Wertz et al. 1974) mais conhecido como fiabilidade compósita (FC): para um factor j com k indicadores, a FC é definida por Fornell e Larcker (1981) como:

$$\widehat{FC}_j = \frac{(\sum_{i=1}^k \lambda_{ij})^2}{(\sum_{i=1}^k \lambda_{ij})^2 + \sum_{i=1}^k \varepsilon_{ij}} \quad (3.26)$$

Onde λ_{ij} são os pesos factoriais na sua forma estandardizada e $\varepsilon_{ij} = 1 - R_{ij}^2 \cong 1 - \lambda_{ij}^2$ são os erros ou resíduos de cada indicador. A fiabilidade compósita estima a consistência interna dos indicadores reflexivos do factor ou constructo, indicando o grau (0-1) em que estes indicadores são, consistentemente, manifestações do factor latente. De uma forma geral, considera-se que $FC_j \geq 0.7$ é indicador de uma fiabilidade de constructo apropriada ainda que, para investigações exploratórias, valores abaixo de 0.7 possam ser aceitáveis (Hair, Anderson, Tatham, & Black, 1998).

- c) *Análise de componentes principais de um conjunto*: um conjunto pode ser considerado unidimensional se o seu primeiro *eigenvalue* (valor que representa a variância nos indicadores explicada pelos sucessivos factores) da matriz de correlação for superior a 1, e os restantes valores inferiores a 1 (regra de Kaiser).

De acordo com Chin (1998), o rho de Dillon-Goldstein é considerado melhor indicador do que o alfa de Cronbach. Na verdade, este último assume a equivalência de Tau das variáveis manifestas, ou seja, é assumido que cada variável manifesta apresente igual importância na definição da variável latente. O rho de Dillon-Goldstein não assenta neste pressuposto; este indicador baseia-se nos resultados do modelo em vez das correlações observadas entre as variáveis manifestas da base de dados.

Nos modelos formativos, cada variável manifesta ou cada subconjunto de variáveis manifestas representa uma dimensão diferente do conjunto subjacente. Deste modo, ao invés do modelo reflexivo, o modelo formativo não assume a homogeneidade nem a unidimensionalidade do conjunto.

Validade

A validade é a propriedade do instrumento ou escala de medida que avalia se esta mede e é a operacionalização do constructo latente que, realmente, se pretende avaliar: “A validade diz respeito ao aspecto da medida ser congruente com a propriedade medida dos objectos, e não com a exactidão com que a mensuração é feita” (Pasquali, 2003, p.158). De acordo com Anasti e Urbina (1997, pp. 113-149) a validade é constituída por 3 componentes: a validade relacionada com o conteúdo, a validade relacionada com o constructo e a validade relacionada com o critério. No âmbito da AEE, é relativamente fácil estimar a validade relacionada com o constructo determinada, por sua vez, por 3 componentes: validade factorial, validade convergente e validade discriminante. A validade factorial (Dunn, Seaker & Waller, 1994; Garver & Mentzer, 1999) ocorre quando a especificação dos indicadores de um determinado constructo é correcta (i.e., os indicadores medem o factor latente que se pretende medir). A validade convergente (Anderson e Gerbin, 1988) demonstra-se quando o constructo sob estudo se correlaciona positiva e significativamente com outros constructos teoricamente paralelos e quando os indicadores que constituem o constructo apresentam correlações positivas e elevadas entre si. Finalmente, a validade discriminante (Anderson e Gerbin, 1988) ocorre quando o constructo sob estudo não se encontra correlacionado com constructos que operacionalizam factores diferentes. Estas 3 componentes, em conjunto, permitem demonstrar a validade do constructo.

A validade factorial é geralmente avaliada pelos pesos factoriais estandardizados (λ_{ij}). É usual assumir que se λ_{ij} de todos os indicadores são superiores ou iguais a 0.5, o factor apresenta validade factorial. O λ_{ij}^2 é designado por fiabilidade individual do indicador, correspondendo à fracção da variabilidade total do indicador explicado pelo factor de cujo indicador é uma manifestação. A fiabilidade individual dos indicadores é uma condição necessária, mas não suficiente, para demonstrar a validade factorial. De uma forma geral considera-se que $\lambda_{ij}^2 \geq 0.25$ é indicador de fiabilidade individual apropriada.

A validade convergente ocorre quando os indicadores que são reflexo de um factor saturam fortemente nesse factor, i.e., o comportamento destes indicadores é explicado essencialmente por esse factor. Fornell e Lacker (1981) propuseram avaliar a validade convergente por intermédio da variância extraída média (VEM) pelo factor. Este valor pode ser calculado usando os pesos factoriais estandardizados:

$$\widehat{VEM}_j = \frac{\sum_{i=1}^k \lambda_{ij}^2}{\sum_{i=1}^k \lambda_{ij}^2 + \sum_{i=1}^k \epsilon_{ij}} \quad (3.27)$$

É usual considerar que $\widehat{VEM}_j \geq 0.5$ é indicador de validade convergente adequada (Hair, et al., 1998, p.612).

Finalmente, a validade discriminante, no contexto da AEE, avalia se os indicadores que reflectem um factor não estão correlacionados com outros factores, i.e., os factores, definidos por cada conjunto de indicadores são distintos. A validade discriminante fica demonstrada pela

verificação de uma, ou mais, condições seguintes (Anderson & Gerbin 1988; Fornell & Lacker 1981):

- 1) As VEM dos factores (i e j) forem superiores ou iguais ao quadrado da correlação entre esses factores (ϕ_{ij}^2);
- 2) O teste da diferença dos X^2 entre o modelo com $\phi_{ij} = 1$ (X_r^2) (a correlação entre factores é perfeita) e o modelo com ϕ_{ij} livre (X_u^2) for significativo. As hipóteses do teste são então

$$H_0: X_r^2 = X_u^2 \quad vs. \quad H_1: X_r^2 \neq X_u^2 \quad (3.28)$$

Finalmente, para uma probabilidade α de erro de tipo I, rejeita-se H_0 se $X_{dif}^2 \geq X_{1-\alpha; (gl_r - gl_u)}^2$ onde $X_{1-\alpha; (gl_r - gl_u)}^2$ é o valor crítico da distribuição Qui-quadrado no percentil $1-\alpha$ com $(gl_r - gl_u)$ graus de liberdade. Um teste significativo é indicativo de que os factores i e j não estão perfeitamente correlacionados. i.e., medem constructos diferentes:

- 3) Um I.C. a 95% para ϕ_{ij} estimado por

$$\left[\widehat{\phi}_{ij} - 1.96 \frac{\sigma_{\phi_{ij}}}{\sqrt{n}}; \widehat{\phi}_{ij} + 1.96 \frac{\sigma_{\phi_{ij}}}{\sqrt{n}} \right] \quad (3.29)$$

Não contiver o valor 1.

7º estágio: interpretação e modificação do modelo teórico

O sétimo e último passo que corresponde à interpretação e modificação do modelo, envolve a interpretação dos resultados. O investigador deverá avaliar se os resultados obtidos para o modelo de medida proposto permitem dar significado aos constructos. Deverá também avaliar, com base nas significâncias dos parâmetros do modelo, se é possível aceitar as relações entre os constructos endógenos e exógenos, propostas no modelo estrutural.

Após a interpretação do modelo, o investigador deverá procurar métodos para melhorar o ajuste. Caso o modelo não apresente um bom ajustamento aos dados a primeira conclusão é que o modelo ajustado não é apropriado para explicar a estrutura correlacional das variáveis naquela amostra específica. Contudo, isto não indica que o modelo esteja completamente errado. É possível, com um número de alterações eduzidas, respecificar o modelo para que o ajustamento melhore significativamente. Uma prática corrente na respecificação consiste na avaliação dos resíduos da matriz de correlação ou de covariância prevista. Valores residuais acima de $\pm 2,58$ são considerados estatisticamente significantes, num intervalo de confiança de 95%. A existência de resíduos significantes indica erro na previsão para um par de indicadores, que poderão ser revistos na respecificação do modelo (Hair Jr et al, 2005).

Os índices de modificação – valores calculados para cada relação não estimada possível num modelo – são a segunda fonte para o investigador identificar fontes de melhoramento no modelo. Estes índices estimam a redução (conservadora) da estatística X^2 do modelo, se um parâmetro fixo ou uma restrição de igualdade entre parâmetros for libertado; se erros de medida forem correlacionados; se novas trajetórias estruturais forem adicionadas, etc. Depois de considerada a restimação do modelo e a variação dos graus de liberdade associada, a variação da qualidade de ajustamento pode obter-se com um simples teste de rácio de verosimilhanças (Bollen, 1989, p.293):

$$\begin{aligned} LR &= -2[\log L(\hat{\theta}_r) - \log L(\hat{\theta}_u)] \\ &= (n - 1)(f_{MLr} - f_{MLu}) \end{aligned} \quad (3.30)$$

Onde f_{MLr} é a função de discrepância de ML para o modelo restrito, e f_{MLu} é a mesma função para o modelo com o parâmetro livre. A estatística LR tem distribuição χ^2 com graus de liberdade calculados pela diferença dos graus de liberdade dos dois modelos anteriores, quando o modelo restrito é válido. Valores iguais ou acima de 3,84 sugerem uma redução estatisticamente significativa no qui-quadrado, caso aquele parâmetro determinado seja estimado

Quando o modelo é respecificado, o investigador deve retornar ao estágio 4 e reavaliá-lo. Hair Jr et al. (2005) advertem que, um modelo modificado deverá passar por uma validação cruzada – com dados diferentes dos dados utilizados para estimar o modelo anterior – antes de ser aceite.

3.2. *Métodos assentes na matriz de covariâncias (CBSEM: ML), na matriz de variâncias (PLS) e Bayesianos (Método de Monte Carlo-MC)*

Na AEE, a estimação pode assentar em métodos baseados na matriz de covariâncias (ex. ML), na matriz de variâncias (ex. PLS) ou em métodos Bayesianos (ex. MC). Os métodos assentes na matriz de covariâncias (CBSEM) são desenhados com base na avaliação e validação dos modelos, ao passo que a estimação assente na matriz de variâncias é direccionada para o cálculo computacional dos *scores* ou valores de cada sujeito nos factores, e para a predição dos modelos (Tenenhaus, 2008). Por outras palavras, a distinção básica entre CBSEM e os métodos assentes na matriz de variâncias é que aquele é adaptado para testar modelos, ao passo que este é mais direccionado para a explicação da variância e na realização de predições (Hulland, Ryan, & Rayner, 2010; Tenenhaus, 2008).

Por outro lado, a estimação assente em métodos Bayesianos descreve as estimativas dos parâmetros como representações abstractas das observações baseadas nos dados observados. Para além destas técnicas deferirem no que concerne aos objectivos e perspectivas, ML, PLS e MC também diferem na sua robustez em função da variação das condições dos dados, o que inclui o tamanho amostral, o número e distribuição de indicadores assim como os pesos factoriais estandardizados.

3.3. Métodos baseados na matriz de covariâncias – CBSEM

Este grupo metodológico é o mais utilizado. De acordo com (Ridgon, R.E, 1998) os diferentes métodos assentes na matriz de covariâncias consistem em variações da minimização da função geral comum de discrepância.

$$F = (S - \Sigma)'w^{-1}(S - \Sigma)$$

Onde S é o vector da “unique” (não redundante) elemento da matriz de covariância ou correlação amostral. Σ é um vector paralelo de elementos da matriz implicada no modelo, e w é a matriz dos pesos. Os diferentes métodos correspondem a diferentes matrizes w . Os dois métodos de estimação mais utilizados são os mínimos quadrados generalizados (GLS) (onde w é a matriz de variância-covariância residual) e o método da máxima verosimilhança (ML) (que utiliza a função de ajustamento $\ln|\Sigma| + \text{trace}(S/\Sigma) - \ln|S| - p$, onde p é o numero de indicadores). Os métodos ML produzem estimadores assintoticamente não enviesados, consistentes e eficientes sob as condições empíricas de que os indicadores seguem uma distribuição normal multivariada; quando a amostra é grande e as observações são independentes [1]. Quando esses pressupostos não são verificados, estes métodos podem produzir soluções improprias como variâncias negativas estimadas.

Assumindo um modelo de equações estruturais formado por um conjunto de variáveis exógenas latentes (ξ_i) operacionalizadas pelos indicadores x_i e os erros de medida associados δ_i , e um conjunto de variáveis latentes endógenas (η_j) operacionalizadas pelos indicadores (y_j) e os erros de medida associados. Se todas as variáveis latentes existentes no modelo forem medidas por indicadores reflectivos, o modelo de equações estruturais seguinte pode ser expresso através de um conjunto de equações teóricas e de medida que descrevem as relações do modelo estrutural e de medida respectivamente.

Submodelo de medida

O submodelo de medida define a forma como os constructos hipotéticos ou variáveis latentes são operacionalizados pelas variáveis observadas ou manifestas. Centrando todas as variáveis¹, o submodelo de medida das variáveis dependentes ou endógenas, pode escrever-se formalmente como (Bollen,1989):

$$y = \Lambda_y \eta + \varepsilon$$

¹Uma variável centrada obtém-se subtraindo a cada observação da variável o valor médio dessa variável.

Onde:

$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_p \end{bmatrix}$ é o vector ($p \times 1$) das p variáveis dependentes, ou de resposta, manifestas;

$\Lambda_y = \begin{bmatrix} \lambda_{11} & \lambda_{12} & \vdots & \lambda_{1r} \\ \lambda_{21} & \lambda_{22} & \vdots & \lambda_{2r} \\ \vdots & \vdots & \vdots & \vdots \\ \lambda_{p1} & \lambda_{p2} & \vdots & \lambda_{pr} \end{bmatrix}$ é a matriz ($p \times r$) dos pesos factoriais de $\boldsymbol{\eta}$ em \mathbf{y} ;

$\boldsymbol{\eta} = \begin{bmatrix} \eta_1 \\ \eta_2 \\ \vdots \\ \eta_r \end{bmatrix}$ é o vector ($r \times 1$) das r variáveis latentes dependentes; e

$\boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_p \end{bmatrix}$ é o vector ($p \times 1$) dos erros de medida de \mathbf{y} .

De forma semelhante, o submodelo de medida para as variáveis independentes ou exógenas centradas é:

$$\mathbf{x} = \Lambda_x \boldsymbol{\xi} + \boldsymbol{\delta}$$

Onde

$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_q \end{bmatrix}$ é o vector ($q \times 1$) das q variáveis independentes ou preditoras manifestas;

$$\Lambda_y = \begin{bmatrix} \lambda_{11} & \lambda_{12} & \vdots & \lambda_{1s} \\ \lambda_{21} & \lambda_{22} & \vdots & \lambda_{2s} \\ \vdots & \vdots & \vdots & \vdots \\ \lambda_{q1} & \lambda_{q2} & \vdots & \lambda_{qs} \end{bmatrix} \text{ é a matriz } (q \times s) \text{ dos pesos factoriais de } \xi \text{ em } \mathbf{x};$$

$$\xi = \begin{bmatrix} \xi_1 \\ \xi_2 \\ \vdots \\ \xi_s \end{bmatrix} \text{ é o vector } (s \times 1) \text{ das } s \text{ variáveis latentes independentes ou predictoras; e}$$

$$\delta = \begin{bmatrix} \delta_1 \\ \delta_2 \\ \vdots \\ \delta_q \end{bmatrix} \text{ é o vector } (q \times 1) \text{ dos erros de medida de } \mathbf{x}.$$

Submodelo estrutural

O submodelo estrutural define as relações causais ou de associação entre as variáveis latentes. Formalmente, este modelo, de novo com as variáveis centradas, pode escrever-se como (Bollen,1989):

$$\eta = \mathbf{B}\eta + \mathbf{\Gamma}\xi + \zeta$$

Onde

$$\mathbf{B} = \begin{bmatrix} 0 & \beta_{12} & \vdots & \beta_{1r} \\ \beta_{21} & 0 & \vdots & \beta_{2r} \\ \vdots & \vdots & \vdots & \vdots \\ \beta_{r1} & \beta_{r2} & \vdots & 0 \end{bmatrix} \text{ é a matriz } (r \times r) \text{ dos coeficientes de } \eta \text{ no modelo estrutural com}$$

$$\beta_{ii} = 0$$

$$\mathbf{\Gamma} = \begin{bmatrix} \gamma_{11} & \gamma_{12} & \vdots & \gamma_{1s} \\ \gamma_{21} & 0 & \vdots & \gamma_{2s} \\ \vdots & \vdots & \vdots & \vdots \\ \gamma_{r1} & \gamma_{r2} & \vdots & \gamma_{rs} \end{bmatrix} \text{ é a matriz } (r \times s) \text{ dos coeficientes de } \mathbf{x} \text{ no modelo estrutural ; e}$$

$\zeta = \begin{bmatrix} \zeta_1 \\ \zeta_2 \\ \vdots \\ \zeta_r \end{bmatrix}$ é o vector ($r \times 1$) dos r resíduos ou erros do modelo estrutural (*disturbances*)

O modelo de equações estruturais, formalizado anteriormente, assume que os diferentes erros ou resíduos dos submodelos de medida e estrutural tem valor esperado nulo e podem estar correlacionados entre si, mas não entre diferentes submodelos. O modelo assume então que:

- a. ε e η são independentes
- b. δ e ξ são independentes
- c. ζ e ξ são independentes
- d. ζ , ε e δ são mutuamente independentes
- e. Os valores esperados dos erros são 0.

Por outro lado, uma variável dependente não é causa efeito dela mesmo, i.e.,

- f. $\beta_{ii} = 0$ e
- g. $(I-B)$ é uma matriz invertível (não singular) onde I é a matriz identidade.

Deste modo, olhando para as equações (1,2 e 3), as aproximações por CBSEM estimam um vector de parâmetros do modelo θ de modo que a resultante matriz de covariância predita pelo modelo teórico $\Sigma = \Sigma(\theta)$ seja o mais semelhante (perto) da matriz de covariância amostral (S).

Número de indicadores por constructo

Como Long (1983) constata, CBSEM requer um número mínimo de indicadores para assegurar a identificação do modelo uma vez que a matriz de covariância amostral (S) deve incluir pelo menos tantos elementos não redundantes como o número de parâmetros a estimar pelo modelo. Baumgartner and Homburg (1996) vai ainda mais longe afirmando que cada variável latente deve ser medida pelo menos por três ou quatro indicadores no âmbito de assegurar resultados fiáveis. Posteriormente, parece ter emergido um consenso geral, que defende que um acréscimo no número de indicadores está associado a efeitos positivos. Por exemplo, Velicer and FAVA (1987) mostram que um aumento no número de indicadores provoca um decréscimo no risco de soluções impróprias, e Marsh, Hau, Balla and Grayson (1998) sugerem que um maior número de indicadores leva a um aumento do número de soluções consistentes, de parâmetros estimados mais precisos e maior fiabilidade. Contudo, estas descobertas são

válidas até um certo limite na medida em que demasiados indicadores podem levar a um poder excessivo nos testes de ajustamento (MacCallum, Browne, & Sugawara, 1996) o que por sua vez pode limitar significativamente a utilidade do CBSEM (Haenlein & Kaplan, 2004).

Tamanho amostral

Na AEE, tanto o método de estimação ML como GLS, requerem um tamanho amostral suficiente para assegurar a identificação do modelo, uma vez que CBSEM requer que a matriz de covariância amostral (S) seja positiva-definida, o que se torna garantido quando o tamanho amostral excede o número de indicadores (Long, 1983). Não obstante, devido às propriedades assintóticas da estimação por ML é necessário um tamanho mínimo amostral para a geração de resultados com precisão suficiente. Consistente com este pensamento, Gerbing & Anderson (1985) mostraram que o erro padrão do modelo estimado diminui com o aumento do tamanho amostral. Como regra base, o tamanho amostral deve exceder as 200 observações na maioria das situações (Boomsma & Hoogland, 2001), e várias estratégias têm sido recomendadas se o tamanho amostral disponível se localiza abaixo deste número, incluindo a utilização de parcelas assentes nos itens como indicadores dos constructos latentes (e.g., Marsh et al., 1998; Nasser & Wisenbaker, 2003) ou o uso de uma técnica de estimação alternativa tal como Mínimos Quadrados não Ponderados (Balderjahn, 1986). Deste modo, estas estratégias podem ser associadas a riscos significativos (e.g., Kim & Hagtvet, 2003).

Distribuição dos indicadores

Tal como outrora enunciado por Jöreskog (1967), CBSEM assenta no método da Máxima Verosimilhança e requer que as variáveis observadas sigam uma distribuição normal multivariada. No entanto, como não é muito provável que uma pesquisa empírica consiga cumprir este pressuposto (Micceri, 1989), alguns autores investigaram o comportamento do estimador ML assente no método CBSEM com indicadores não normalmente distribuídos e verificaram que os erros padrão de CBSEM tendem a ser inflacionados (Babakus, Ferguson, & Jöreskog, 1987). Deste modo, e para remediar a não normalidade dos dados algumas medidas alternativas são recomendadas, tais como o aumento do tamanho amostral, (Bandalos, 2002) e técnicas de estimação alternativas (Sharma, Durvasula, & Dillon, 1989)

Pesos factoriais estandardizados

Constructos mal operacionalizados constituem um problema para qualquer tipo de análises empíricas, na medida em que podem confundir a construção do conhecimento teórico. Deste modo, um conjunto de indicadores, utilizado para a operacionalização de uma variável latente deve ser válido e fiável (Churchill, 1979). A fiabilidade de um constructo pode ser expressa em função dos pesos factoriais estandardizados dos indicadores, e os pesos factoriais médios coincidem com uma maior fiabilidade (Gerbing & Anderson, 1988). Uma vez que a fiabilidade pertence à porção da variância causada pelo (indesejado) erro aleatório, pesos elevados são

geralmente preferidos aos pesos baixos. Relativamente à variabilidade dos pesos dos indicadores que pertencem ao mesmo constructo, o caso permanece menos claro. Assumindo uma média constante para os pesos (i.e., $\lambda_1 + \lambda_2 = 2\bar{\lambda}$ para dois indicadores) a variância média extraída (AVE) (Fornell & Larcker, 1981), que corresponde à medida da validade do constructo será mínima se os pesos forem iguais para todos os indicadores do mesmo constructo. Deste modo, pesos desiguais devem ser preferidos aos pesos equivalentes uma vez que os primeiros levam a uma maior validade. Esta afirmação também se ajusta com a opinião de que um grau elevado de homogeneidade nos indicadores deve ser evitado pois pode ser indicador da redundância dos itens. (Boyle, 1991).

4. Métodos baseados na matriz de variâncias (VBSEM) - mínimos quadrados parciais (PLS)

VBSEM (PLS) é um método de modelação baseado na matriz de variância desenvolvido por Wold (1975) em alternativa aos métodos de estimação baseados na matriz de covariância (CBSEM). Comparado com as aproximações tradicionais à AEE (i.e, ML), PLS pode ser descrito como um método mais flexível, cujo objectivo passa por minimizar a quantidade de variância das variáveis dependentes que é explicada pelas variáveis independentes (Haenlein & Kaplan, 2004; Wold, 1975). PLS é particularmente adequado para amostras pequenas (Chin & Newsted, 1999; Haenlein & Kaplan, 2004; Hulland et al., 2010), circunstâncias onde o número de indicadores que compõem as variáveis latentes é elevado (Chin & Newsted, 1999; Haenlein & Kaplan, 2004), casos em que os indicadores formativos servem como fonte primária de mensuração directa (Fornell & Bookstein, 1982; MacCallum & Browne, 1993), situações em que os dados apresentam distribuições enviesadas (Bagozzi & Yi, 1994), e má especificação do modelo estrutural (Cassell, Hackl, & Westlund, 1999).

Tal como qualquer modelo de equações estruturais, o modelo PLS contém uma parte estrutural (que reflecte as relações entre as variáveis latentes) e uma componente de medida, que descreve as relações entre os indicadores e as variáveis latentes correspondentes. Contudo, este método comporta ainda uma terceira componente. Esta componente diz respeito às relações ponderadas (*weight relations*), que são utilizadas na estimação dos *scores* (i.e, valores estimados de cada observação para cada variável latente) das variáveis latentes (Chin & Newsted, 1999).

Ao invés de CBSEM, que estima primeiro os parâmetros do modelo e depois os *scores* através de uma regressão destes com o conjunto dos indicadores (Dijkstra, 1983), PLS começa primeiro pelo cálculo dos *scores*. Para tal, as variáveis latentes não observadas são estimadas como uma combinação linear exacta dos seus indicadores empíricos (Fornell & Bookstein, 1982, p. 441), e PLS trata esta aproximação como se estes indicadores constituíssem substitutos perfeitos das respectivas variáveis latentes (Dijkstra, 1983). Os valores ponderados utilizados no cálculo dos *scores* são estimados de molde a que estes consigam abranger a maior parte da variância das variáveis independentes que é útil na predição das variáveis dependentes (Garthwaite, 1994). Isto assenta no pressuposto de que toda a variância das variáveis no modelo é uma variância útil e que deve ser explicada (Chin, Marcolin, & Newsted, 1996). Deste modo, através do cálculo da média ponderada dos indicadores, a utilização destes pesos vai permitir determinar um valor para cada variável latente não observada.

Isto resulta num modelo em que todas as variáveis latentes não observadas são aproximadas por um conjunto de *scores*, e que estes, por sua vez, podem ser estimados através dum conjunto de regressões efectuadas pelo método dos mínimos quadrados ordinários. Resumidamente, a ideia base do PLS é bastante evidente: em primeiro lugar são estimadas as relações ponderadas que ligam os indicadores às respectivas variáveis latentes correspondentes, e em segundo lugar, são calculados os *scores* para cada variável latente, assentes numa média ponderada dos indicadores introduzindo estas relações ponderadas.

Finalmente, os “valores caso” são utilizados num conjunto de regressões que vão determinar os parâmetros das relações estruturais (Fornell & Bookstein, 1982).

Esta explicação põe em evidência que a parte crucial da análise por PLS consiste na estimação das relações ponderadas, no entanto, devido a isto, PLS apresenta duas desvantagens: (1) não existe uma teoria racional para que todos os indicadores apresentem o mesmo peso. Uma vez que se assume que os parâmetros estimados resultantes do modelo estrutural dependem do tipo de ponderação utilizada, (pelo menos até que o número de indicadores não seja excessivamente grande, McDonald, 1996), o pressuposto (exógeno) da igualdade dos pesos faz com que os resultados sejam altamente arbitrários. (2) como constataram Chin, Marcolin, e Newsted (2003), tal procedimento não tem em conta o facto de que alguns indicadores possam ser mais fiáveis do que outros, devendo estes receber pesos mais elevados.

Deste modo, ao ser um método com informação limitada (Dijkstra, 1983), PLS tem a vantagem de não requerer quaisquer pressupostos acerca da população ou da escala de medida (Fornell & Bookstein, 1982, p. 443) e consequentemente, o facto de poder trabalhar sem requerer o cumprimento de quaisquer pressupostos distribucionais, permite-lhe modelar variáveis nominais, ordinais e intervalares. No entanto, existe um outro lado menos positivo na análise por PLS denominado de consistência por aumento (consistency at large). Geralmente um estimador consistente pode ser descrito como “aquele que converge em probabilidade para o valor do parâmetro a ser estimado à medida que o tamanho amostral aumenta” (McDonald, 1996, p. 248). Contudo, porque os valores caso em PLS correspondem a agregados das variáveis manifestas que envolvem o erro de medida, devem, à partida, ser considerados inconsistentes (Fornell & Cha, 1994).

Assim, os coeficientes estruturais estimados através do PLS, convergem para os valores dos parâmetros do modelo composto pelas variáveis latentes em causa à medida que o tamanho amostral e o número de indicadores de cada variável latente tende para infinito (McDonald, 1996, p. 248). Este problema é conhecido como consistência por aumento. Não obstante, nas situações reais da vida quotidiana, nas quais tanto o número de observações como o número de indicadores são finitos, PLS tende a subestimar as correlações entre as variáveis latentes e sobrestimar os pesos factoriais estandardizados (i.e., os parâmetros do modelo de medida; Dijkstra, 1983). Este problema apenas desaparece quando o número de observações e o nº de indicadores por variável latente tende para infinito, uma vez que, nesse caso, os valores caso das variáveis se aproximam dos valores verdadeiros, minimizando este problema (Lohmöller, 1989).

Número de indicadores por constructo e tamanho amostral

O método PLS não trabalha com variáveis latentes mas com variáveis bloco uma vez que estas são produto de combinações lineares de um conjunto de indicadores que normalmente envolvem erros de medida. Por esta razão, os scores determinados para cada variável bloco e para cada caso, tal como as estimativas dos parâmetros associados, devem ser considerados inconsistentes. Estas convergem para os valores da sua verdadeira população apenas quando o número de indicadores e o tamanho amostral tendem para infinito (Hui & Wold, 1982; Schneeweiss, 1993). Nas situações da vida real, PLS tende a subestimar os parâmetros do modelo e sobrestimar os parâmetros do modelo de medida (Dijkstra, 1983). Contudo, para um determinado número de indicadores, mesmo um aumento ilimitado do tamanho amostral não daria origem a estimativas não enviesadas (um termo para isto), e dado um determinado tamanho amostral, qualquer aumento do número de indicadores por constructo apenas pode provocar um decréscimo parcial na variância dos parâmetros estimados.

Por sua vez, o método PLS serve particularmente para casos nos quais CBSEM atinge os seus limites tal como quando o número de indicadores por variável latente se torna excessivamente grande (tal como no caso da ressonância magnética), ou quando o tamanho amostral é pequeno. Por exemplo uma simulação de Monte Carlo realizada por Chin and Newsted (1999) mostra que PLS pode trazer extrair informação a partir de tamanho amostral com 20 observações.

Distribuição dos indicadores

Especificamente PLS não requer quaisquer pressupostos para além da distribuição da escala de medida dos indicadores utilizados (Dijkstra, 1983). A única característica que deve ser preenchida é que a porção sistemática de todas as regressões lineares OLS deve ser equivalente ao valor esperado condicional das variáveis dependentes (Wold, 1975). Esta condição que é muitas vezes referida como “especificação preditiva”, implica que o modelo estrutural seja um sistema de relações causais com resíduos não correlacionados, e que os resíduos que pertencem a uma variável latente sejam não correlacionados com as correspondentes variáveis latentes preditoras. A estabilidade da estimação de parâmetros por PLS na presença de distribuições enviesadas tem vindo a ser confirmada na simulação de Monte Carlo realizada por Cassel, Hackl, and Westlund (1999).

Pesos factoriais estandardizados dos indicadores

Relativamente aos pesos factoriais estandardizados dos indicadores, os mesmos pontos descritos para CBSEM podem ser aplicados. Não obstante, é esperado que o PLS seja mais robusto na presença de constructos operacionalizados inapropriadamente, uma vez que estimação simultânea aproximada por CBSEM implica que um constructo fraco possa influenciar todas as estimativas dos parâmetros e estimativas das variáveis latentes, enquanto no PLS a possibilidade de tais efeitos negativos é limitada ao constructo em si e às variáveis na sua vizinhança.

Análise e avaliação do modelo estrutural

Existem três questões principais que são necessárias abordar no que diz respeito às relações estruturais na modelação por caminhos PLS (Wold, 1985):

- 1) Relações lineares: ao passo que CBSEM estima em primeiro lugar os parâmetros do modelo, PLS estima os valores das variáveis latentes como produto de combinações lineares dos indicadores (Haenlin & Kaplan, 2004). Deste modo, o primeiro aspecto a considerar num modelo estrutural (interior) diz respeito à verificação da linearidade das relações estruturais de molde a que estas possam ser expressas por (Lohomoller, 1989):

$$LV_j = \beta_0 + \sum_{i \rightarrow j} \beta_{ji} LV_i + error_j \quad (4.1)$$

onde o i associada a LV_i representa todas as variáveis latentes que são preditivas de LV_j . Os coeficientes β_{ji} correspondem aos coeficientes de trajectória e representam a força e direcção das relações entre as respostas LV_j e os preditores LV_i . β_0 representa o termo de intercepção e o termo $error_j$ representa os resíduos.

- 2) Modelos recursivos: a segunda questão a considerar é o facto do sistema de equações ter que ser um sistema recursivo. Isto significa que não permite relacionamentos recíprocos entre variáveis latentes.

- 3) Especificação da regressão: o 3º aspecto a ter em conta nas relações estruturais diz respeito à especificação das regressões. Neste caso, a ideia base é que as relações lineares sejam concebidas a partir de uma perspectiva estandardizada da regressão:

$$E(LV_j|LV_i) = \beta_{0i} + \sum_{i \rightarrow j} \beta_{ji} LV_i \quad (4.2)$$

Deste modo, a equação prévia, expressa o condicionamento subjacente aos valores esperados da variável resposta LV_j determinados pelos preditores LV_i . O único pressuposto extra é:

$$cov(LV_j, error_j) = 0 \quad (4.3)$$

O que significa que a variável latente LV_j é não correlacionada com o erro residual. É importante referir que, até agora, não se está a pressupor nada acerca da distribuição das variáveis ou dos erros. Apenas se está a requerer a existência dos momentos de 1ª e 2ª ordem das variáveis.

O processo estimativo

As estimativas PLS são obtidas através de um processo iterativo constituído por cinco passos (Henseler, 2010; Tenenhaus, 2008) durante os quais, a subparte do modelo é sequencialmente estimada. É a simplicidade da aproximação da análise de regressão sequencial que permite a utilização de PLS em amostras pequenas. Uma vez que os parâmetros são estimados individualmente ou em blocos, as complexidades do modelo não são tidas simultaneamente em conta, e deste modo, amostras de grande dimensão não são necessárias (e.g., Reinartz, Haenlein, & Henseler, 2009).

Os cinco passos incluídos no processo do PLS, durante os quais os valores dos parâmetros do modelo de medida (exterior) e estrutural (interior) são estimados são:

- 1º passo: cada variável latente é agrupada nos seus indicadores para criar blocos de variáveis e respectivas relações.

- 2º passo: as aproximações exteriores dos scores das variáveis latentes são calculadas como combinações lineares dos indicadores associados a cada variável latente.

$$\eta = w_1x_1 + w_2x_2 \dots + w_px_p \quad (4.4)$$

Onde η é a variável latente, x_1-x_p são as variáveis manifestas associadas à respectiva variável latente (independentemente do modelo especificar se a porção de mensuração é reflectiva ou formativa) e $w_1- w_p$ são os pesos atribuídos a cada indicador.

- 3º passo: os pesos interiores (w) são calculados no âmbito de reflectir a força com que uma variável latente esta relacionada com outras variáveis latentes do modelo. Existem três métodos possíveis para calcular os pesos interiores: (1) centroide, (2) pesos factoriais e (3) pesos de trajectória (Henseler, 2010; Monecke & Leisch, 2012; Tenenhaus, 2008).

O método do centroide estima os pesos interiores assentes no sinal da correlação entre uma VL e as VLs subjacentes. Os pesos estruturais são definidos como (Lohmoller, 1989):

$$\epsilon_{ij} = \begin{cases} \text{sign}[cor(Y_j, Y_i)] & LV_j, LV_i \text{ adjacentes} \\ 0 & \text{caso contrário} \end{cases} \quad (4.5)$$

Esta opção não considera nem a direcção nem a força da trajectória do modelo estrutural.

O método dos pesos factoriais estima os pesos interiores assentes em combinações de relações entre uma VL e as VLs adjacentes. Este esquema utiliza o coeficiente de correlação como peso estrutural em vez de utilizar apenas o sinal da correlação. Deste modo o peso estrutural é definido como:

$$\epsilon_{ji} = \begin{cases} cor(Y_j, Y_i) & LV_j, LV_i \text{ adjacentes} \\ 0 & \text{caso contrário} \end{cases} \quad (4.6)$$

Este esquema considera não só, o sinal da direcção, mas também a força da trajectória do modelo estrutural. O método dos pesos de trajectória consiste na estimação dos pesos interiores, e tem em atenção as direcções do sentido das setas que correlacionam as variáveis latentes do modelo.

- 4º passo: as aproximações interiores aos scores das variáveis latentes são calculadas como combinações lineares das aproximações exteriores dos scores das variáveis latentes (valores obtidos no 2º passo).
- 5º passo: as estimações dos pesos externos são calculadas baseando-se nas relações entre cada variável latente e seus indicadores. No caso dos indicadores reflectivos, os pesos externos são calculados como a covariância entre os indicadores e as aproximações internas dos scores das variáveis latentes, obtidos no 4º passo (este método é conhecido como Modo A). No caso dos indicadores formativos os pesos exteriores são calculados em função dos pesos obtidos através da regressão OLS das aproximações interiores dos scores das variáveis latentes nos indicadores associados com a variável latente (Modo B).

Os passos 2-5 são iterativos até a formação das estimativas dos pesos exteriores sofrerem uma alteração de critério, no qual o 2º passo é repetido e os scores das variáveis latentes são calculados como:

$$\eta_1'' = w_2\eta_2' + \dots + w_i\eta_j' + w_x\xi_1' + \dots + w_i\xi_i' \quad (4.7)$$

Onde $w_1 - w_p$ são os pesos obtidos durante o 3º passo, η são as estimativas das variáveis latentes endógenas (4º passo), e ξ são as estimativas das variáveis latentes exógenas.

Os índices de qualidade:

A qualidade do modelo estrutural é examinada recorrendo a três índices de qualidade: (1) o coeficiente de determinação (R^2); (2) o índice de redundância e (3) o índice de bondade de ajustamento (GOF).

Coeficiente de determinação (R^2)

A medida mais comum utilizada na avaliação do modelo estrutural é o coeficiente de determinação (R^2). Este coeficiente representa a precisão da predição do modelo e é calculada como o quadrado da correlação entre os valores preditos e observados dum constructo endógeno específico. Este coeficiente indica a quantidade de variância presente no constructo endógeno latente que é explicada pela (s) variável (s) latente (s) independente (s). Este índice

varia entre 0 e 1, onde os valores mais elevados indicam maior poder de predição. Alguns investigadores classificam este índice em três categorias: 1. baixo: $R^2 < 0.30$ (embora alguns autores considerem $R^2 < 0.20$), 2. Moderado: $0.30 < R^2 < 0.60$ (mas também se pode considerar $0.20 < R^2 < 0.50$), e 3. Elevado: $R^2 > 0.60$ (alternativamente também se pode considerar $R^2 > 0.50$) (Hair, Ringle, & Sarstedt, 2011; Henseler et al., 2009).

Índice de Redundância

No âmbito de avaliar o desempenho da previsão do modelo de medida no modelo estrutural, o índice de redundância, calculado para o bloco j -th mede a porção de variação das variáveis manifestas relacionadas com a variável latente j -th explicada pelas variáveis latentes ligadas directamente a este bloco, i.e.:

$$Rd(LV_k, mv_{jk}) = loading_{jk}^2 R_k^2 \quad (4.8)$$

Uma medida da qualidade global do modelo estrutural pode ser fornecida pelo índice médio de redundância que é calculado como:

$$\overline{Red} = \frac{1}{J} \sum_{j=1}^J Red_j \quad (4.9)$$

Onde J corresponde ao número total de variáveis latentes endógenas do modelo. Uma redundância elevada corresponde a uma maior capacidade de previsão.

Bondade de ajustamento (GOF)

O índice de bondade de ajustamento (GOF; Tenenhaus et al., 2005), foi desenvolvido com o objectivo de avaliar a qualidade das estimativas obtidas através da estimação por PLS. O valor de ajustamento é calculado a partir dos valores de R^2 obtidos para os modelos de medida e estrutural, calculando 1º o índice de comunalidade (Tenenhaus et al., 2005). Para GOF, o índice de comunalidade para cada bloco (cada variável latente e respectivas variáveis observadas) pode ser calculado:

$$C_j = \frac{1}{p_j} \sum_{h=1}^{p_j} corr^2(x_{jh}, \eta_j) \quad (4.10)$$

Onde j é um bloco, p é o número de variáveis manifestas, x é a variável resposta manifesta, e η_j é o score componente. O índice de comunalidade é calculado para cada bloco, e a comunalidade média para o modelo de medida é calculado:

$$\bar{C} = \frac{1}{p} \sum_{j=1}^J p_j C_j \quad (4.11)$$

Finalmente, o valor da bondade de ajustamento global é calculado como a raiz quadrada da comunalidade média, multiplicado pelos valores médio de R^2 como:

$$GOF = \sqrt{\bar{C} \times R^2} \quad (4.12)$$

Validação dos modelos de medida e estrutural:

Uma vez que PLS não requer o cumprimento de quaisquer pressupostos, os níveis de significância para a estimação dos parâmetros não são adequados. Como alternativa, são utilizados procedimentos de reamostragem tais como blindfold ou bootstrap, que, através de testes de significância permitem obter informação acerca da variabilidade dos parâmetros.

O método bootstrap em AEE

O método de reamostragem bootstrap é uma aproximação não paramétrica na inferência estatística onde os parâmetros a estimar não requerem o cumprimento de qualquer pressuposto distribucional ao contrário dos métodos tradicionais. Bootstrap esboça conclusões acerca das características populacionais a partir e unicamente da amostra recolhida em vez de tirar conclusões não realistas acerca da população, isto é, dada a ausência de informação acerca da população, a amostra é assumida como sendo a melhor representação da população. Deste modo, bootstrap mostra ser mais vantajoso em situações onde a teoria estatística acerca da distribuição de parâmetros é fraca ou inexistente, ou quando os pressupostos inferenciais são violados (Mooney,1996).

Bootstrap estima a distribuição amostral empírica dos parâmetros através de um processo de reamostragem com reposição, apesar de cada réplica ter o mesmo número de elementos da amostra original, este método de reamostragem assegura que cada réplica seja ligeira e aleatoriamente diferente da amostra original (Mooney & Duval,1993). Se a amostra é uma boa aproximação da população, o método bootstrap fornece uma boa aproximação da distribuição amostral dos parâmetros.

Na AEE, bootstrap permite a realização de testes de significância de uma estatística (θ) tal como uma trajectória ou um peso factorial standardizado. Tais testes de significância analisam a probabilidade de observar uma estatística tao grande ou maior quando a hipótese nula $H_0 : \theta=0$, e verdadeira (Bollen and Stine,1992). Como muitos investigadores trabalham com amostras relativamente pequenas e provenientes de populações cuja distribuição não é normal (o mesmo acontece quando se divide a amostra inicial em grupos menores, causando uma redução no numero de observações em cada subamostra), o processo de reamostragem bootstrap oferece uma alternativa viável na medida em que, como o método PLS-SEM não trabalha com variáveis latentes mas antes com variáveis bloco, e estima os parâmetros do modelo com o intuito de maximizar a quantidade de variância explicada pelos constructos endógenos através de uma serie de regressões de mínimos quadrados comuns (Reinartz et al., 2009). Deste modo os PLS baseados nos modelos de equações estruturais assumem à partida que a distribuição amostral é razoavelmente representativa da presumida distribuição populacional. O teste de hipótese inerente à técnica bootstrap é consequentemente: $H_0: w=0$ (onde w representa qualquer parâmetro estimado via PLS) versus $H_1: w \neq 0$ at $m+n-2$ graus de liberdade (onde m representa o número de estimativas PLS para cada w na amostra original, a qual é 1; n corresponde ao numero de estimativas bootstrap para w , e.g., 5000). Os resultados PLS para todas as amostras bootstrap fornecem o valor médio e o correspondente desvio padrão para cada coeficiente estrutural. Esta informação permite a realização do teste t de student para obter o valor de probabilidade que permite avaliar a significância das relações de estruturais do modelo em estudo.

Em suma, PLS é visto como um método mais adequado para o trabalho exploratório do que para a modelação confirmatória uma vez que os coeficientes resultantes são geralmente consistentes mas enviesados, comparados aos outros métodos de estimação (Cassell et al., 1999; Lohmöller, 1989). Especificamente, nas aplicações em dados caracterizados por terem amostras pequenas e pequeno número de indicadores por VL, Dijkstra (1983) informa que PLS tem tendência para subestimar as correlações entre as variáveis latentes (o modelo estrutural) e sobrestimar os pesos factoriais standardizados (modelo de medida).

Vantagens e desvantagens de PLS

A primeira vantagem de PLS sobre os métodos de estimação CBSEM reside no facto de que este assenta no método de regressão dos mínimos quadrados ordinários (OLS) para obtenção das estimativas dos parâmetros (Jöreskog & Wold, 1982; Wold, 1982) e reamostragem bootstrap para a estimação dos erros padrão (Monecke & Leisch, 2012), o que lhe permite estar livre de cumprir fortes pressupostos distribucionais (Bagozzi & Yi, 1994; Fornell & Bookstein, 1982; Hwang & Takane, 2004; Wold, 1982).

PLS é especialmente flexível pois pode ser aplicado a todo o tipo de dados independentemente da escala de medida (Haenlein & Kaplan, 2004). Cassel et al. (1999) demonstraram a robustez do PLS em situações em que os modelos contêm indicadores enviesados ou multicolineares e até quando o modelo estrutural apresenta má especificação (misspecification). Uma vantagem adicional do PLS é que este é conhecido por não convergir em soluções inadequadas (improper solutions) (Fornell & Bookstein, 1982; Hanafi, 2007).

A primeira desvantagem do PLS é que este não trabalha para a minimização do critério global optimizado (i.e., a função de ajustamento; McDonald, 1996), e devido a isto não há maneira significativa de definir como é que os modelos PLS são optimizados. Deste modo, não existe uma estimativa de ajuste geral nos modelos PLS o que torna difícil avaliar o desempenho deste método de estimação (Hwang & Takane, 2004; McDonald, 1996). Um método alternativo para avaliar o desempenho do PLS tem sido o de realçar a recuperação dos coeficientes de regressão dentro do modelo estrutural (e.g., Vinzi et al., 2010). Apesar da ausência de pressupostos e sendo renovado futuramente para lidar com problemas mais complexos de modelação nos anos recentes, PLS parece não ser bem compreendido por parte dos investigadores para prever o seu desempenho correcta e consistentemente. Por exemplo, Hwang, Malhotra, et al. (2010), informam que PLS produz erros padrão estimados mais precisos que ML sob má especificação do modelo, mas ML supera PLS na mesma situação mas quando o modelo é correctamente especificado.

5. VBSEM (PLS) versus CBSEM (ML)

CBSEM (ML) e VBSEM (PLS) divergem em vários pontos. As diferenças provêm das funções para os quais estes métodos foram feitos assim como dos tipos de procedimentos estimativos que eles utilizam. A tabela 5.1 apresenta as diferenças mais importantes entre os dois métodos. Como se pode verificar, estas diferenças residem no facto de que com CBSEM as variáveis observadas devem cumprir o pressuposto da normalidade multivariada, os tipos de modelos a ajustar podem ser recursivos ou não recursivos, é necessária a identificação de parâmetros, a correlação entre os erros de medida pode ser modelada, as estimativas são consistentes de acordo com a correcção do modelo e a adequabilidade dos pressupostos, existem testes estatísticos válidos e disponíveis assim que os pressupostos do modelo chave são verificados, existe uma grande variedade de medidas de ajuste, existem métodos disponíveis para estimar determinado tamanho amostral e analisar o poder estatístico e os scores das variáveis latentes não são estimados directamente ao passo que com PLS as variáveis observadas não requerem o cumprimento de qualquer pressuposto, os tipos de modelos a ajustar podem ser apenas recursivos, a identificação de parâmetros não é relevante, a correlação entre os erros de medida não pode ser modelada, as estimativas são “consistentes por aumento”, tornando-se mais consistentes à medida que o tamanho amostral e o número de indicadores por variável latente aumentam, a inferência requer *jackknif* ou *bootstrap*, estão disponíveis medidas de validade e fiabilidade, o tamanho amostral pode ser pequeno a moderado, os scores das variáveis latentes são estimados como resultado de combinações lineares exactas de variáveis observadas.

No entanto, apesar de Wold (1975) ter desenvolvido o procedimento estimativo (PLS) para a modelação causal em alternativa ao CBSEM, as aproximações assentes na matriz de covariâncias (ML, GLS, ULS) e as aproximações assentes na matriz de variâncias (PLS) podem, ao invés de competitivas, ser consideradas complementares.

De acordo com Jöreskog (1982,p.270), ML é orientado para a teoria e dá ênfase à transição da análise confirmatória para a análise exploratória, ao passo que o objectivo primário de PLS incide sobre a análise causal preditiva, em situações de elevada complexidade mas de baixa informação teórica. Deste modo, o investigador pode optar pela escolha de CBSEM se o objectivo do estudo passa por testar e desenvolver teoria, ou pela modelação por caminhos PLS se o objectivo assenta em aspectos preditivos.

Apesar de em CBSEM existir uma perda de precisão na predição devido á indeterminação das estimativas dos scores factoriais, esta ocorrência não incide sobre a avaliação da teoria, onde as relações estruturais (i.e, estimação de parâmetros) entre conceitos são de importância primária. Adicionalmente, a construção de hipóteses e avaliação de resultados em CBSEM através do critério de ajustamento global dá maior ênfase à avaliação da teoria do que à construção da mesma (Anderson&Gerbing,1988).

Por outro lado, ao utilizar uma técnica de estimação iterativa, a modelação de caminhos PLS calcula os scores das variáveis latentes como uma combinação linear das medidas observadas. Deste modo, a aproximação evita o problema da indeterminação e fornece uma definição exacta dos scores dos componentes (Fornell,1982).

A aproximação PLS é adequada para a modelação causal cujo objectivo passa pela predição ou construção da teoria (theory building). Apesar da modelação por caminhos PLS poder ser utilizada para confirmar teoria, esta assume que toda a variância medida é útil na explicação de aplicações (e.g., Sarkar, Echambadi, Cavusgil, & Aulakh, 2001) e indica as relações causais com efeito significativo. Assim, as estimativas dos parâmetros são obtidas com base na capacidade de minimizar as variâncias residuais das variáveis dependentes (latentes e observadas).

PLS carece de uma função de optimização geral e, consequentemente, as medidas de ajustamento global limitam definitivamente o uso de PLS no teste da teoria. O investigador deve chegar a uma conclusão na análise do modelo causal com variáveis latentes no intuito de seleccionar uma técnica estatística apropriada. Em vez de utilizar o modelo para explicar a covariância entre os indicadores, que é objectivo de CBSEM, a modelação por caminhos PLS maximiza a variância explicada de todas as variáveis dependentes e, deste modo, suporta os objectivos da predição

Estimação de parâmetros e inferência:

Uma importante diferença entre CBSEM e PLS reside na estimação de parâmetros. Quando os pressupostos requeridos são verificados, e quando o tamanho amostral é grande, as estimativas fornecidas pelo método da máxima verosimilhança proporcionadas por CBSEM são não enviesadas e de variância mínima (M.V.U.E). Ainda assim, no caso da violação de certos pressupostos, estas estimativas podem ser relativamente robustas e apresentar várias características desejáveis.

Com PLS, as estimativas dos scores das variáveis latentes são “consistentes por aumento”, isto é, à medida que o número de indicadores e o tamanho amostral aumentam, as estimativas tornam-se mais consistentes. Sob condições dum número finito de indicadores e observações, a falta de completa consistência nos scores pode produzir estimativas enviesadas nos pesos factoriais standardizados e nos coeficientes estruturais. Não existe uma solução definida na estimação do tamanho do viés nos estimadores PLS (Lohmoller, 1989; Chin, 1998a).

A flexibilidade da utilização de PLS provém do facto de esta técnica não requerer a verificação de quaisquer pressupostos acerca das distribuições das variáveis, e isto proporciona a liberdade de utilização de qualquer tipo de indicadores. Em contrapartida, parte do preço a pagar por esta vantagem é a de não haver possibilidade de aplicação de testes estatísticos directos. PLS não fornece testes estatísticos para a significância dos parâmetros nem para o ajustamento do modelo e nem para a diferença entre modelos, no entanto, a inferência é possível devido à utilização de procedimentos como *jackknif* ou *bootstrap*.

Em contrapartida, com CBSEM é possível obter as estimativas dos erros padrão dos parâmetros estimados, diversos testes de ajustamento, comparar estatísticas de modelos aninhados e tem a capacidade para testar a flexibilidade dos parâmetros do modelo no que diz respeito à linearidade. Ainda assim, e apesar de CBSEM requerer a verificação de certos pressupostos distribucionais, quando estes não são sustentáveis, a inferência acerca dos parâmetros pode ser feita recorrendo ao método *bootstrap*. CBSEM pode ser ajustado a dados

de múltiplos grupos simultaneamente e as diferenças entre modelos para os grupos podem ser testadas. Elas podem ser usadas para estimar médias e valores de intercepção para as variáveis latentes.

Em suma, ambos os métodos diferem de um ponto de vista estatístico, e por isso nenhuma técnica se pode considerar superior à outra, nem nenhuma é apropriada para todas as situações. Geralmente, as vantagens de PLS são as desvantagens de CBSEM e vice-versa. É importante que os investigadores entendam a razão do desenvolvimento e aplicação das duas técnicas e que as utilizem adequadamente.

Tabela 5.1: Características de CBSEM e PLS

| Característica | CBSEM | PLS |
|--|---|---|
| Pressupostos distribucionais | Para estimação por ML ou GLS as variáveis observadas tem que apresentar distribuição normal multivariada. Para estimação por ADF/WLS as variáveis observadas tem que ser distribuídas continuamente. | Nenhum |
| Tipos de modelos que podem ser ajustados | Recursivos e não recursivos | Recursivos |
| Tipos de variáveis observadas | Continuas Discretas ordenadas (utilização das correlações policóricas como entrada assumindo robustez). | Continuas Discretas ordenadas e não ordenadas |
| Tipos de variáveis latentes que podem ser modeladas | Continuas | Continuas |
| Tipo de indicadores para as variáveis latentes (VL) | Efeito (seta da VL para o indicador) Causal (seta do indicador para a VL) | Reflectivos, formativos (análogos aos indicadores-efeito e indicadores causais) |
| Identificação de parâmetros | Deve ser considerada | Não é relevante para modelos padrão PLS |
| Factores por indicador | Uma variável observada pode indicar mais do que uma VL | As variáveis observadas podem indicar apenas uma VL |
| Correlação entre as VLs pode ser estimada indirectamente | sim | nao |
| A correlação entre os erros de medida pode ser modelada | sim | nao |
| Estimação de médias e valores de intercepção nas VLs | sim | nao |
| Tipo de algoritmo de ajuste | A estimação de parâmetros é realizada minimizando as discrepâncias entre as matrizes VCV (ou matriz de correlação) preditas e observadas. Métodos de informação completa. | Processo iterativo multi estágios utilizando OLS. O modelo é dividido em dois blocos cujos parâmetros são estimados separadamente. Método de informação limitado. |
| Nota: adaptado de Bacon.L, 1999 | | |

Tabela 5.1: (continuação)

| Característica | CBSEM | PLS |
|--|---|---|
| Consistência dos estimadores | Consistentes de acordo com a correcção do modelo e a adequabilidade dos pressupostos. | “Consistentes por aumento”. As estimativas tornam-se mais consistentes quando o tamanho amostral e o número de indicadores por VL aumentam. |
| Disponibilidade de testes estatísticos para as estimativas | Válidos e disponíveis assim que os pressupostos do modelo chave são verificados. Caso contrário é necessária inferência por bootstrap. | A inferência requer <i>jackknif</i> ou <i>bootstrap</i> . |
| Medidas de ajuste | Existe uma grande variedade. Devem ser seleccionadas de acordo com a teoria distribucional. | Estão disponíveis medidas de validade e fiabilidade. |
| Verificação da qualidade do modelo de medida | Existem medidas para verificar a validade e fiabilidade que permitem às variáveis observadas a indicação de uma ou mais VL. | Existem medidas para verificar a validade e fiabilidade. |
| Exigências relativas ao tamanho amostral | Maior do que para regressão múltipla. Existem métodos disponíveis para estimar determinado tamanho amostral e analisar o poder estatístico. | Pequeno a moderado. É aconselhado a utilização entre 10 a 20 observações por parâmetro no maior modelo-bloco. Ver “consistência dos estimadores.” |
| Indeterminação factorial | Os scores das variáveis latentes não são estimados directamente. | Nenhuma. Os scores das variáveis latentes são estimados como resultado de combinações lineares exactas de variáveis observadas. |
| Possibilidade de modelação de factores de 2ª ordem | sim | sim |
| Estimação de coeficientes aleatórios | Sim, para alguns tipos de modelos | não |
| Dados perdidos | Os algoritmos assumem os dados completos mas a imputação pode ser feita através de alguns pacotes SEM disponíveis nos softwares. | Assume os dados completos. Imputação utilizando apenas outro software. |
| Nota: adaptado de Bacon.L, 1999 | | |

6. A simulação na AEE

No contexto da investigação, a simulação é a prática da geração de dados para que estes tomem características específicas para os propósitos da avaliação em causa ou para os desempenhos das técnicas analíticas. A vantagem da utilização de dados simulados em relação aos dados reais é que, uma vez que o investigador cria os dados, este tem o controlo completo sobre as características dos dados e relações entre as variáveis. O facto de saber os valores verdadeiros do modelo utilizado para simular os dados (i.e., modelo populacional) permite ao investigador a condução de uma avaliação empírica de vários métodos analíticos comparando os resultados de várias técnicas analíticas às verdades conhecidas sobre os dados (Paxton, Curran, Bollen, Kirby, & Chen, 2001). A simulação é um bom método de investigação na AEE (e.g., Anderson & Gerbing, 1984; Curran, West, & Finch, 1996; Gerbing & Anderson, 1993; Hu & Bentler, 1999; Hwang et al., 2010), e tem vindo a ser utilizada para estudar o desempenho dos métodos de estimação (e.g., Henseler & Chin, 2010; Hwang et al., 2010), testes estatísticos e índices de ajustamento (e.g., Anderson & Gerbing, 1984; Curran, et al., 1996; Hu & Bentler, 1999), os efeitos do modelo e características dos dados tais como o tamanho amostral (e.g., Fan, Thompson, & Wang, 1999; Hox & Maas, 2001) e má especificação (e.g., Hwang et al., 2010).

A simulação de Monte Carlo na Análise de Equações Estruturais

Os estudos de Monte Carlo, frequentemente referidos como estudos de simulação, têm vindo a desempenhar um papel importante na avaliação das propriedades dos estimadores e procedimentos na AEE. As principais razões para implementar a simulação de Monte Carlo na AEE são:

- 1) Na AEE, a teoria assintótica da maioria dos estimadores, assim como outros pressupostos exigidos pelo modelo, entram em conflito com a realidade empírica do trabalho de pesquisa quotidiano, criando uma necessidade de estudos de robustez. Como as propriedades dos estimadores de Máxima Verosimilhança apenas são conhecidas assintoticamente sob o pressuposto da normalidade, estes tornam-se difíceis de derivar analiticamente quando a amostra é finita e não segue uma distribuição normal. Deste modo, quando existe uma violação específica dos pressupostos requeridos, a robustez dos estimadores é posta em causa (Boomsma, 1983).
- 2) A existência de vários estimadores, variando desde os mínimos quadrados ordinários até aos estimadores robustos por mínimos quadrados ponderados leva a uma inevitável comparação estatística entre eles (e.g., Siemsen & Bollen, 2007). A questão implícita neste caso reside na escolha acertada do estimador segundo as condições empíricas estabelecidas.

- 3) O desempenho de procedimentos específicos de modelação, tais como a selecção de modelos (Green, Thompson, & Poirer, 2001) ou o modo como lidar com dados perdidos (Enders & Bandalos, 2001; Gold & Bentler, 2000) é muitas vezes desconhecido teoricamente. Se o investigador tiver que escolher entre um conjunto de procedimentos de modelação, a questão mais pertinente é sem dúvida que aproximação estatística escolher de acordo com as circunstâncias.

Em qualquer dos casos, a simulação de Monte Carlo pode ser uma ferramenta poderosa na medida em que fornece respostas aproximadas às questões referidas nos pontos anteriores. O interesse comum em tais questões é que os investigadores que trabalham com modelos de equações estruturais possam saber como realizar escolhas apropriadas e alternativas viáveis sob condições específicas.

Estimativas dos parâmetros e erros padrão

No âmbito de avaliar o desempenho entre os dois métodos de estimação no que concerne aos parâmetros e erros padrão, o presente estudo analisou as estimativas estandardizadas para todos os resultados. Apesar de, na investigação por simulação, as estimativas não estandardizadas serem utilizadas com mais frequência na avaliação do modelo estimado pelo método da ML, o *software* utilizado na estimação por PLS apenas permite as estimativas estandardizadas.

Estimação de parâmetros

A qualidade dos parâmetros estimados para os modelos de medida e estrutural foi avaliado de acordo com o viés (e.g., Hutchinson & Bandalos, 1997). Neste contexto, o viés é definido como a proporção da diferença entre os valores amostrais e os valores populacionais (Enders & Bandalos, 2001), e é calculado:

$$\%BIAS = \left[\frac{|\theta_i - \theta_B|}{\theta_B} \right] \times 100 \quad (6.1)$$

Onde θ_i é o parâmetro estimado e θ_B o parâmetro populacional desconhecido. Em cada réplica, a média do viés do modelo de medida e estrutural é calculada separadamente.

Erro padrão

A precisão dos erros padrão associados aos parâmetros estimados dos modelos de medida e estrutural será avaliada em termos da diferença média absoluta entre os erros padrão estimados e os erros padrão empíricos (MAD; Hwang, Malhotra, et al., 2010), e é calculado:

$$MAD = \frac{\sum_{j=1}^p |SE(\bar{\theta}_j) - SE(\theta_j)|}{p} \quad (6.2)$$

Onde $SE(\bar{\theta}_j)$ é o erro padrão estimado, $SE(\theta_j)$ é o verdadeiro valor do erro padrão, e p é o número de parâmetros. Os verdadeiros erros padrão empíricos foram calculados como:

$$SE(\theta_j) = \sqrt{\frac{\sum_{i=1}^B (\theta_j - \bar{\theta}_j)^2}{B - 1}} \quad (6.3)$$

Onde θ_j é o parâmetro estimado, obtido para uma única réplica, e $\bar{\theta}_j$ é a média do parâmetro estimado obtido em B replicações (Hwang, Malhotra, et al., 2010; Sharma, Durvasula, & Dillon, 1989; Srinivasan & Mason, 1986). Em cada replicação, MAD foi calculada separadamente para cada modelo de medida e modelo estrutural separadamente. A capacidade dos métodos de estimação na produção de erros padrão foi também avaliado através da construção de um intervalo de confiança para cada parâmetro estimado e determinando quando o correspondente parâmetro populacional é incluído dentro deste intervalo (i.e., precisão das estimativas do erro padrão; Gerbing & Anderson, 1985). Para este propósito, o intervalo de confiança foi definido como ± 1.96 erros padrão à volta do parâmetro estimado, e o valor de interesse é a proporção de parâmetros estimados para o qual o parâmetro populacional é incluído dentro do intervalo de confiança apropriado. Este valor foi calculado para cada réplica para reflectir a precisão dos erros padrão associados com os modelos de medida e estrutural separadamente.

7. Variáveis, Amostras e Modelo teórico

O objectivo geral deste capítulo é descrever as amostras, as variáveis latentes e manifestas utilizadas no estudo, o modelo teórico conceptual especificado a partir de referências literárias, assim como a hipótese de investigação subjacente ao estudo.

Operacionalização das variáveis

As variáveis são constituídas por conceitos. Estes conceitos têm definições gerais que é necessário esclarecer de forma precisa. Por isso, o investigador deve operacionaliza-los, dando-lhes um sentido facilmente observável, que permita avaliar e medir. A descrição operacional das variáveis deve conter construções teóricas e a justificar da adequação dos instrumentos utilizados.

7.1.1. Variável latente independente

A variável latente independente, também designada como variável exógena latente, corresponde à qualidade da governança (governança-Gov). A governança compreende uma transformação de um tipo de relação onde um lado governa outro num conjunto de relações, onde uma interacção mútua ocorre no âmbito de proporcionar escolhas desejáveis aos cidadãos. Deste modo, a governança engloba um poder político, económico e administrativo que as sociedades utilizam para administrar as suas actividades. Isto envolve mecanismos, processos e instituições que os cidadãos, grupos e sociedades utilizam para tomar decisões e implementações conjuntas, expressar os seus interesses, preencher as suas obrigações, assim como resolver os seus conflitos. Neste contexto, a governança mostra a natureza das interacções mutuas entre os agentes sociais, assim como os agentes sociais e a administração pública (Toksöz, 2008). É importante referir que, neste estudo, a qualidade da governança engloba também a qualidade institucional das populações (Kaufmann, Kraay, and Mastruzzi, 2003). Existem 6 indicadores que medem a percepção da qualidade da governança e que foram extraídos de mais de 25 bases de dados a nível mundial. Deste modo, de acordo com (Kaufmann et al. 2003) os seis indicadores da governança foram divididos em três grupos distintos:

Processo pelo qual os governos são seleccionados orientados e substituídos

- 1) Voz e responsabilização (va): mede a percepção da qualidade dos processos políticos, liberdades civis e direitos políticos em determinado país.
- 2) Estabilidade política e ausência de violência (sta): mede a percepção da probabilidade que o governo tem de cair.

Capacidade governamental para formular e implementar novas políticas

- 3) Eficácia governamental (eg): eficácia inerente à capacidade governamental para implementar e produzir boas políticas e redistribuir os bens públicos.
- 4) Qualidade regulatória (qr): é direccionado para políticas tais como a incidência de políticas hostis e percepção das dificuldades causadas pela regulação excessiva.


O respeito dos cidadãos e do estado relativamente às instituições que governam as interacções económicas e sociais.

- 5) Estado de direito (rl): vários indicadores medem a confiança que os diversos agentes têm e a sua tendência de acordo com as regras da sociedade. De acordo com Kaufmann et al. (2003, p.4) estes indicadores medem o sucesso da sociedade, desenvolvendo um ambiente no qual as regras justas e previsíveis formam a base das interacções sociais e económicas.
- 6) Controle da corrupção (cc): mede a percepção da corrupção (exercício de poderes públicos para ganho privado)

7.1.2. Variável latente dependente

A variável latente dependente, ou variável endógena latente, corresponde à qualidade de vida (QV) das populações. O diagrama representado na figura apresenta um esquema dos indicadores estatísticos básicos utilizados neste trabalho para a formação da variável latente qualidade de vida em determinado país.

Figura 7.1: Sistema hierárquico de índices estatísticos, critério parcial e indicadores sintéticos da qualidade de vida usados no estudo (de acordo com S. Aivazian).



- Pegada ecológica (EF): a pegada ecológica é definida como a área territorial/terrestre necessária associada ao consumo da população e com capacidade para absorver todos os excedentes provenientes da mesma (Wackernagel and Rees 1995). O consumo é dividido em cinco categorias: 1) comida, 2) habitação, 3) transporte, 4) bens de consumo e 5) serviços. A terra, por sua vez é dividida em 6 categorias: 1) energia terrestre, 2) terra degradada ou em utilização, 3) jardins, 4) terra cultivada, 5) pastagens e florestas de gestão, e 6) terra com pouca disponibilidade, considerada como as florestas intocáveis e áreas não produtivas as quais os autores definem como desertos e culturas de gelo. Os dados são recolhidos de diferentes fontes tais como contagens de produção e mercado, ou o uso de combustíveis agrícolas e estatísticas de emissões. Deste modo, a pegada ecológica é calculada pela compilação de uma matriz na qual a área terrestre está distribuída para cada categoria de consumo. Finalmente, para calcular a pegada ecológica *per capita*, todas as áreas terrestres são adicionadas e posteriormente divididas pela população, por conseguinte, o resultado é expresso em hectares *per capita*.
- Liberdade económica mundial (EFW): este índice abrange cerca de 100 países e territórios desde 1980. As pedras fundamentais da liberdade económica são: (1) escolha pessoal, (2) trocas voluntárias e coordenadas pelos mercados, (3) liberdade de participação e competição nos mercados e (4) protecção pessoal e sua propriedade em caso de agressão por parte de outrem. Deste modo, a liberdade económica está presente quando aos indivíduos é permitido ter escolha própria e participar em transacções voluntariamente desde que não ameacem/interfiram com outros indivíduos ou propriedades alheias. Em ampla escala, o índice EFW é um esforço para identificar o quão perto as políticas e instituições de um país correspondem à ideia de um governo limitado, onde este protege o direito à propriedade e organiza para a prestação de um conjunto limitado de bens públicos tais como a defesa nacional e acesso ao dinheiro, mas pouco além destas funções centrais. Para um país obter um valor EFW elevado, este deve providenciar uma protecção segura da propriedade privada alcançada mesmo com aplicação imparcial dos contractos, assim como um ambiente monetário estável.
- Facilidade de acesso ao saneamento básico (SN): a facilidade de acesso ao saneamento básico refere-se à percentagem da população com pelo menos um acesso adequado a infra-estruturas de eliminação de excreções. Estas podem efectivamente prevenir o contacto humano, animal, e insectívoro com excrementos. Instalações melhoradas vão desde latrinas simples mas protegidas até autoclismos com conexão de redes de esgotos. Para ser eficaz, as facilidades devem ser correctamente construídas e adequadamente mantidas (base de dados do Banco Mundial).

- Produto interno bruto (GDP): o produto interno bruto é um agente indicador do desenvolvimento de um país. Um maior nível de desenvolvimento corresponde, geralmente, a uma maior capacidade de pagar e receber impostos, tal como uma relativamente alta plasticidade dos vencimentos relativos aos bens e serviços públicos (Chelliah, 1971; Bahl, 1971) (base de dados do Banco Mundial).
- Índice de percepção ambiental (EPI): este índice foi desenvolvido em 163 países e é baseado em 25 indicadores agrupados em dez categorias de acordo com um critério político: degradação ambiental, poluição atmosférica (efeitos em seres humanos), água (efeitos em seres humanos), poluição atmosférica (efeitos no ecossistema), água (efeitos no ecossistema), biodiversidade & Habitat, silvicultura, pesca, agricultura e alterações climáticas. O ranking de EPI é alcançado com base na sensibilidade que cada país apresenta aos pressupostos assumidos pela estrutura do índice e da agregação dos 25 indicadores subjacentes. Os pressupostos a testar são: (1) os erros de medida dos dados em bruto, (2) A estrutura do EPI – agrupado pelas diferentes categorias de política, (3) pesos atribuídos aos indicadores e/ou às categorias políticas, (4) função de agregação aos níveis políticos ou ao nível dos objectivos, e (5) número de indicadores ou categorias políticas.
- Índice de mortalidade infantil (IMR): A mortalidade infantil é, geralmente, estimada sob a forma de um coeficiente ou taxa de mortalidade infantil, o qual traduz o número de óbitos de crianças, com menos de 1 ano, ocorridos durante um determinado período de tempo, (normalmente um ano) relativamente ao número de nados-vivos do mesmo período, sendo o valor estimado em número de crianças mortas por cada 1000 nados-vivos. Este coeficiente pode ainda ser dividido em mortalidade infantil. A mortalidade infantil é um dos principais indicadores de saúde pública, uma vez que traduz vários aspectos do estado e condições das populações tais como a disponibilidade de assistência médica, de estruturas de apoio médico (hospitais) e sanitário, condições socioeconómicas, incidência de doenças infecto-contagiosas e alterações genéticas, entre outros dados. Os factores que influenciam os valores do coeficiente de mortalidade infantil são diversos, podendo-se mencionar, como potenciadores, o baixo nível socioeconómico, o consumo de tabaco, álcool e estupefacientes, várias doenças maternas (como hipertensão, diabetes, sida, sífilis e infecção por estreptococos do grupo B), a ocorrência de malformações congénitas, ausência de cuidados pré-natais e de apoio ao parto, más condições higienó-sanitárias e a ocorrência de partos prematuros (base de dados do Banco Mundial).
- Taxa de literacia total (LT). A taxa de literacia total corresponde á percentagem da população com idade igual ou superior a 15 anos, capazes de ler e escrever compreensivelmente uma narração curta e simples no seu quotidiano. Geralmente, a literacia também engloba a “numeracia”, ou seja, a capacidade de realizar cálculos aritméticos simples. Este indicador é calculado dividindo o número de literatos com

idade igual ou superior a 15 anos pelo grupo etário correspondente, multiplicando o resultado por 100 (base de dados do Banco Mundial).

7.2. Amostra

Após identificar o problema em estudo, o maior desafio consistiu em encontrar indicadores para todos os países do mundo que pudessem reflectir a hipótese em estudo. Contudo, com base na literatura, verificou-se que não existe um consenso a nível das várias organizações sobre o número exacto de países no mundo. A ONU conta 193, mas o Banco Mundial e a FIFA (Federação Internacional de Futebol Associado) tem números diferentes. Para um estado ser reconhecido como país, tem que apresentar determinados requisitos, a saber: 1) um território definido, 2) um governo, 3) uma moeda, 4) uma população permanente e 5) e apresentar características e dados. Contudo, a ONU não considera possessões e territórios.

Para ser constituído país, este deve ter fronteiras definidas, sustentação económica e soberania nacional (reconhecimento de outros países da ONU, principalmente dos mais fortes). Existem porém, estados/territórios que suscitam duvidas quanto à sua classificação, é o caso do Kosovo, uma vez que a Rússia bloqueia a entrada deste país na ONU, o Vaticano, considerado estado "observador permanente" com direito a voto nas conferências, e Taiwan, porque a China considera Taiwan como uma província rebelde. Em suma, recorrendo a indicadores medidos por instituições tais como o Banco Mundial (World Bank), Nações Unidas, Fundo Monetário Internacional, World Values Survey ou Fórum Económico Mundial, foi possível edificar uma base de dados composta por 215 países/áreas territoriais que reflecte a amostra total considerada para o estudo (tabela 7.1). Posteriormente, de acordo com o critério estabelecido pelo Banco Mundial relativamente ao *status* de cada país, esta amostra deu origem, numa primeira fase, a duas subamostras que correspondem aos países desenvolvidos e países subdesenvolvidos, e numa segunda fase a três subamostras que correspondem aos países com rendimento baixo, países com rendimento médio baixo e países com rendimento médio alto.

A organização do Banco Mundial (World Bank).

O Banco Mundial é uma fonte fundamental de assistência financeira e técnica para os países subdesenvolvidos de todo o mundo. Não se trata de um banco no sentido usual da palavra, mas de uma organização única que pretende reduzir a pobreza e aprovar o desenvolvimento. Este grupo foi criado em 1944, tem a sua sede na cidade de Washington e conta com mais de 10.000 empregados distribuídos por mais de 120 filiais em todo o mundo. Este grupo consiste em cinco principais organizações:

- O Banco Internacional de Reconstrução e Fomento (BIRF), que concede empréstimos a governos de países com média e baixa capacidade de pago.
- A associação Internacional de Fomento (AIF), que concede empréstimos sem juros ou créditos, assim como doações a Governos dos países mais pobres.
- A Corporação Financeira Internacional (IFC), membro do Grupo do Banco Mundial, é a maior instituição internacional de desenvolvimento, dedicada exclusivamente ao sector privado. Ajudam os países subdesenvolvidos a alcançar um crescimento sustentável, financiando investimentos, mobilizando capitais nos mercados financeiros internacionais e prestando serviços de acessória a empresas e governos.
- O organismo Multilateral de Garantia de Investimentos (MIGA), foi criado em 1998 como membro do Grupo do Banco Mundial para promover o investimento estrangeiro directo nos países subdesenvolvidos, apoiar o crescimento económico, reduzir a pobreza e melhorar a vida das pessoas. O MIGA cumpre este mandato oferecendo seguros aos investidores contra riscos políticos.
- O Centro Internacional de Ajuste de Diferenças Relativas a Investimentos (CIADI), presta serviços internacionais de conciliação e arbitragem para ajudar a resolver disputas sobre investimentos.

As organizações que constituem o Banco Mundial pertencem aos governos dos países membros. Estes países têm o último poder de decisão no interior de cada organização no que diz respeito aos mais variados assuntos incluindo questões políticas, financeiras ou relacionais. Os países membros controlam o grupo do Banco Mundial através de regras estabelecidas pelos governantes e directores executivos tomando as decisões cruciais para as organizações. Para ser considerado membro do Banco Mundial, de acordo com os artigos IBRD um país deve, fazer parte do fundo monetário internacional (FMI). Este grupo tem dois principais objectivos que consistem em 1) terminar com a pobreza extrema no curso de uma única geração e 2) promover a prosperidade compartilhada. Para acabar com a pobreza extrema, a meta do Banco é reduzir em 3% a percentagem de pessoas que vivem com menos de 1.00360€ por dia antes do final de 2030. Para fomentar a prosperidade compartilhada, a meta consiste em promover o crescimento dos ingressos da população de todos os países que se situa 40% abaixo da distribuição do ingresso.

Tabela 7.1: Lista de Países constituintes da amostra total em estudo.

| | | | |
|-----------------------|-------------------|---------------------|--------------------------|
| Afeganistão | Rep. Dominicana | Líbia | São Marino |
| Albânia | Equador | Liechtenstein | São tome e Príncipe |
| Algéria | Egipto | Lituânia | Samoa Americana |
| Arábia Saudita | El salvador | Luxemburgo | Senegal |
| Andorra | Guiné Equatorial | Macao | Sérvia |
| Angola | Eritreia | Macedónia | Seychelles |
| Anguila | Estónia | Madagáscar | Serra leoa |
| Antígua e barbuda | Etiópia | Malawi | Singapura |
| Argentina | Ilhas Fiji | Malásia | Eslováquia |
| Arménia | Finlândia | Maldivas | Eslovénia |
| Aruba | França | Mali | Ilhas Salomão |
| Austrália | Guiana francesa | Malta | Somália |
| Áustria | Gabão | Ilhas Marechal | Africa do sul |
| Azerbaijão | Gâmbia | Martinique | Sudão do Sul |
| Bahamas | Geórgia | Mauritânia | Espanha |
| Bahrein | Alemanha | Mauritios | Sri Lanka |
| Bangladesh | Gana | México | São. Kitts e Nevis |
| Barbados | Grécia | Micronésia | Sta. Lúcia |
| Bielorrússia | Gronelândia | Moldova | São vicente e Granadinas |
| Bélgica | Grenada | Mónaco | Sudão |
| Belize | Guam | Mongólia | Suriname |
| Benim | Guatemala | Montenegro | Suazilândia |
| Bermuda | Guiné | Marrocos | Suécia |
| Botão | Guiné Bissau | Moçambique | Suíça |
| Bolívia | Guiana | Myanmar | Síria |
| Bósnia | Haiti | Namíbia | Taiwan |
| Botswana | Honduras | Nauru | Tadjiquistão |
| Brasil | Hong Kong | Nepal | Tanzânia |
| Brunei | Hungria | Holanda | Tailândia |
| Bulgária | Islândia | Antilhas holandesas | Timor Leste |
| Burquina | Índia | Nova Caledónia | Togo |
| Burundi | Indonésia | Nova Zelândia | Tonga |
| Camboja | Irão | Nicarágua | Trindade e Tobago |
| Camarões | Iraque | Níger | Tunísia |
| Canada | Irlanda | Nigéria | Turquia |
| Cabo verde | Israel | Niue | Turquemenistão |
| Ilhas Caimão | Itália | Noruega | Tuvalu |
| Rep. Africana Central | Jamaica | Omã | Uganda |
| Chade | Japão | Paquistão | Ucrânia |
| Chile | Jersey | Palau | Emir. Árabes unidos |
| China | Jordânia | Panamá | Reino unido |
| Colômbia | Cazaquistão | Papua e Nova Guiné | Estados unidos |
| Cômodos | Quénia | Paraguai | Uruguai |
| Congo, Rep. Dem. | Kiribati | Peru | Usbequistão |
| Congo, Rep. | Coreia, Rep. Dem. | Filipinas | Vanuatu |
| Ilhas Cook | Coreia, Rep. | Polónia | Venezuela |
| Costa Rica | Kosovo | Portugal | Vietnam |
| Costa do Marfim | Kuwait | Porto rico | Ilhas virgens |
| Cuba | Quirguistão, Rep. | Qatar | Gaza |
| Chipre | Lao | Reunião | Iémen |
| Rep. Checa | Letónia | Roménia | Zâmbia |
| Dinamarca | Líbano | Rússia | Zimbabwe |
| Djibouti | Lesotho | Ruanda | |
| Dominicana | Libéria | Samoa | |

Países desenvolvidos

Os países com rendimento elevado, (*high income countries*), são definidos pelo *World Bank* como aqueles cujo rendimento nacional bruto (GNI) é superior a 10,1283€ (Tabela 7.2). O termo “país de rendimento elevado” é também conhecido como “país desenvolvido” ou “país do primeiro mundo” o qual se refere também aos países que se aliaram aos estados unidos e à NATO durante a guerra fria.

Tabela 7.2: Grupo formado pelos países desenvolvidos segundo o critério do Banco Mundial.

| | | | |
|-------------------|------------------|---------------------|---------------------|
| Andorra | Rep. Checa | Coreia, Rep. | Qatar |
| Antígua e barbuda | Dinamarca | Kuwait | Rússia |
| Aruba | Guiné equatorial | Letónia | São Marino |
| Austrália | Estónia | Liechtenstein | Arabia saudita |
| Áustria | Finlândia | Lituânia | Singapura |
| Bahamas | França | Luxemburgo | Eslováquia |
| Bahrain | Alemanha | Macao | Eslovénia |
| Barbados | Grécia | Malta | Espanha |
| Bélgica | Gronelândia | Mónaco | São. Kilts e Nevis |
| Bermuda | Guam | Holanda | Suécia |
| Brunei | Hong Kong | Antilhas Holandesas | Suíça |
| Canada | Islândia | Nova Caledónia | Trindade e Tobago |
| Ilhas Caimão | Irlanda | Nova Zelândia | Emir. Árabes unidos |
| Chile | Israel | Noruega | Reino unido |
| Ilhas Cook | Itália | Polonia | Estados Unidos |
| Croácia | Japão | Portugal | Uruguai |
| Chipre | Jersey | Porto rico | Ilhas Virgem |

Países subdesenvolvidos

Os países subdesenvolvidos (Tabela 7.3), também conhecidos como países em vias de desenvolvimento, são todos aqueles onde o padrão de vida é considerado baixo. Para além disso, estes países costumam apresentar uma base industrial pouco desenvolvida acompanhada por um índice de desenvolvimento humano relativamente baixo (HDI). Até agora, o produto interno bruto (GDP) tem sido utilizado pelas diversas instituições como ponto de referência para a divisão entre países desenvolvidos e subdesenvolvidos, apesar de não existir ainda um critério universal que consiga definir o que é realmente um país desenvolvido ou subdesenvolvido e que países encaixam nessas duas categorias.

Tabela 7.3: Grupo formado pelos países subdesenvolvidos segundo o critério do Banco Mundial.

| | | | |
|-----------------------|-------------------|---------------------|-------------------------|
| Afganistão | Equador | Madagáscar | Senegal |
| Albânia | Egipto | Malawi | Servia |
| Argélia | El Salvador | Malásia | Seychelles |
| Samoa Americana | Eritreia | Maldivas | Serra leoa |
| Angola | Etiópia | Mali | Ilhas Salomão |
| Anguila | Fiji | Ilhas Marechal | Somália |
| Argentina | Guiana Francesa | Martinique | África do sul |
| Arménia | Gabão | Mauritânia | Sudão do Sul |
| Azerbaijão | Gambia | Mauritios | Sri Lanka |
| Bangladesh | Geórgia | México | Sta. Lúcia |
| Bielorrússia | Gana | Micronésia | S. Vicente e Granadinas |
| Belize | Grenada | Moldova | Sudão |
| Benim | Guatemala | Mongólia | Suriname |
| Botão | Guiné | Montenegro | Suazilândia |
| Bolívia | Guiné Bissau | Marrocos | Síria |
| Bósnia | Guiana | Moçambique | Taiwan |
| Botswana | Haiti | Myanmar | Tadjiquistão |
| Brasil | Honduras | Namíbia | Tanzânia |
| Bulgária | Hungria | Nauru | Tailândia |
| Burquina | Índia | Nepal | Timor Leste |
| Burundi | Indonésia | Nicarágua | Togo |
| Camboja | Irão | Níger | Tonga |
| Camarões | Iraque | Nigéria | Tunísia |
| Cabo Verde | Jamaica | NIUE | Turquia |
| Rep. Africana central | Jordânia | Omã | Turquemenistão |
| Chade | Cazaquistão | Paquistão | Tuvalu |
| China | Quênia | Palau | Uganda |
| Colômbia | Kiribati | Panamá | Ucrânia |
| Cômoros | Coreia, Rep. Dem. | Papua e Nova Guiné | Usbequistão |
| Congo, Rep. Dem. | Kosovo | Paraguai | Vanuatu |
| Congo, Rep. | Quirguistão, Rep. | Peru | Venezuela |
| Costa Rica | Lao | Filipinas | Vietnam |
| Costa do Marfim | Líbano | Reunião | Gaza |
| Cuba | Lesoto | Roménia | Iémen |
| Djibouti | Libéria | Ruanda | Zâmbia |
| Dominicana | Líbia | Samoa | Zimbabwe |
| Rep. Dominicana | Macedónia | São Tomé e Príncipe | |

Países com rendimento baixo, rendimento médio-baixo e rendimento médio-alto.

Devido a questões de ordem operacional e analítica, o rendimento nacional bruto per capita (GNI- Gross National Income) foi o principal critério utilizado pelo Banco Mundial no âmbito de classificar as economias dos países. Baseado no GNI *per capita* as economias foram classificadas como; rendimento baixo (low income), rendimento médio (subdividido em rendimento médio-baixo e rendimento médio-alto) ou rendimento elevado (high income, que

corresponde também aos países desenvolvidos). Os países com rendimento médio e baixo são muitas vezes classificados como países subdesenvolvidos, contudo, a classificação de acordo com a economia não reflecte necessariamente o *status* de desenvolvimento. As economias são divididas com base no GNI per capita 2012 e calculadas de acordo com o método World Bank Atlas. Deste modo, os grupos constituídos são: 1) países com rendimento baixo; todos aqueles cujo rendimento é igual ou inferior a 0.83098€ (tabela 7.4); 2) países com rendimento médio-baixo, todos aqueles cujo rendimento se encontra entre 1.09191€ - 3.27975€, (tabela 7.5), e 3) países com rendimento médio alto; todos aqueles cujo rendimento se encontra entre 3.28056€ - 10.1283€ (tabela 7.6); e 4) países com rendimento elevado (também denominados países desenvolvidos); todos aqueles cujo rendimento é igual ou superior a 10.1283€.

Tabela 7.4: Grupo formado pelos países com rendimento baixo segundo o critério do Banco Mundial

| | | | |
|-----------------------|-------------------|------------|--------------|
| Afeganistão | Etiópia | Malawi | Sudão do Sul |
| Bangladesh | Gambia | Mali | Taiwan |
| Burquina | Guine | Moçambique | Tadjiquistão |
| Burundi | Guiné Bissau | Myanmar | Tanzânia |
| Camboja | Haiti | Nepal | Togo |
| Rep. Africana central | Quénia | Níger | Uganda |
| Chade | Coreia, Rep. Dem. | NIUE | Zimbabwe |
| COMOROS | Quirguistão, Rep. | Ruanda | |
| Congo | Libéria | Serra leoa | |
| Eritreia | Madagáscar | Somália | |

Tabela 7.5: Grupo formado pelos países com rendimento médio-baixo segundo o critério do Banco Mundial.

| | | | |
|-----------------|------------|---------------------|---------------|
| Arménia | Guatemala | Mongólia | Ilhas Salomão |
| Butão | Guiana | Marrocos | Sri Lanka |
| Bolívia | Honduras | Nauru | Sudão |
| Camarões | India | Nicarágua | Suazilândia |
| Cabo verde | Indonésia | Nigéria | Síria |
| Congo | Quiribati | Paquistão | Timor Leste |
| Ilhas Cook | Kosovo | Papua e Nova guiné | Ucrânia |
| Costa do marfim | Lao | Paraguai | Usbequistão |
| Djibouti | Lesotho | Filipinas | Vanuatu |
| Egipto | Martinique | Reunião | Vietnam |
| El salvador | Mauritânia | Samoa | Gaza |
| Geórgia | Micronésia | São tome e Príncipe | Iémen |
| Gana | Moldova | Senegal | Zâmbia |


Tabela 7.6: Grupo formado pelos países com rendimento médio-alto segundo o critério do Banco Mundial.

| | | | |
|---------------|-----------------|---------------------|-------------------------|
| Albânia | Costa rica | Líbano | Seychelles |
| Algéria | Cuba | Macedónia | Samoa Americana |
| África do Sul | Dominicana | Malásia | Sta. Lúcia |
| Angola | Rep. Dominicana | Maldivas | S. Vicente e Grenadines |
| Anguila | Equador | Ilhas Marshall | Suriname |
| Argentina | Fiji | Mauritios | Tailândia |
| Azerbaijão | Gabão | México | Tonga |
| Bielorrússia | Grenada | Montenegro | Tunísia |
| Belize | Hungria | Namíbia | Turquia |
| Bósnia | Irão | Antilhas Holandesas | Turquemenistão |
| Botswana | Iraque | Palau | Tuvalu |
| Brasil | Jamaica | Panamá | Venezuela |
| Bulgária | JERSEY | Peru | |
| China | Jordânia | Romena | |
| Colômbia | Cazaquistão | Servia | |

7.3. Modelo de Análise

O modelo conceptual foi elaborado de acordo com o objectivo principal do trabalho que visa estudar o efeito da qualidade de governança no que concerne à qualidade de vida das populações.

Figura 7.2: A figura ilustra um modelo de equações estruturais com duas variáveis latentes. A variável latente Governança, composta por 6 indicadores (voz e responsabilização – va, estabilidade política e ausência de violência – sta, eficácia governamental – eg, qualidade regulatória – qr, estado de direito – rl, e controlo da corrupção – cc) e a variável latente Qualidade de Vida, composta por 7 indicadores (literacia – LT, índice de mortalidade infantil – IMR, qualidade de saneamento básico – SN, índice de percepção ambiental – EPI, pegada ecológica – EF, índice de liberdade económica mundial – EFW e produto interno bruto – GDP).



A relação estrutural do modelo que vinca o efeito que a qualidade de governança tem na qualidade de vida das populações pode ser descrita segundo a equação linear (1)

$$qualidade = \beta_{12}governança + \zeta_1 \quad (1)$$

As relações dos pesos factoriais estandardizados (2) da figura que definem as relações dos indicadores com as respectivas variáveis latentes podem ser escritas como um conjunto de regressões lineares bivariadas, com o respectivo erro de medida associado:

Variável latente governança:

$$\begin{aligned} va &= \lambda_{11}^x governança + \delta_1 & qr &= \lambda_{41}^x governança + \delta_4 \\ sta &= \lambda_{21}^x governança + \delta_2 & rl &= \lambda_{51}^x governança + \delta_5 \\ eg &= \lambda_{31}^x governança + \delta_3 & cc &= \lambda_{61}^x governança + \delta_6 \end{aligned} \quad (2)$$

Variável latente qualidade de vida:

$$\begin{aligned} LT &= \lambda_{21}^y qualidade + \delta_7 \\ IMR &= \lambda_{22}^y qualidade + \delta_8 & EPI &= \lambda_{52}^y qualidade + \delta_{11} \\ SN &= \lambda_{32}^y qualidade + \delta_9 & EFW &= \lambda_{62}^y qualidade + \delta_{12} \\ EF &= \lambda_{42}^y qualidade + \delta_{10} & GDP &= \lambda_{72}^y qualidade + \delta_{13} \end{aligned} \quad (3)$$

Hipótese em estudo

H1: A variável latente Qualidade de Governança tem um impacto positivo e directo significativo na variável latente Qualidade de Vida.

8. Resultados

Os resultados do modelo em estudo cuja hipótese pretende mostrar o efeito que a qualidade de governança tem na qualidade de vida das populações, foram obtidos a partir das duas técnicas associadas à AEE: CBSEM e PLS. Estas duas técnicas de estimação foram aplicadas aos seis grupos de países, classificados de acordo com os critérios enunciados no capítulo 6: 1) o número total de países considerando a amostra completa; 2) o grupo formado pelos países desenvolvidos; 3) o grupo formado pelos países subdesenvolvidos; 4) o grupo formado pelos países com rendimento baixo; 5) o grupo formado pelos países com rendimento médio baixo e, 6) o grupo formado pelos países com rendimento médio alto. Deste modo, os resultados em questão são apresentados em cinco eixos:

- a) **Análise exploratória:** este eixo apresenta as estatísticas descritivas multivariadas e univariadas que sintetizam e resumem a informação contida nos dados, quer através de índices estatísticos (verificação da normalidade assimetria e achatamento) quer através de representações gráficas (caixas de bigodes e gráficos quantil-quantil) para os 6 tamanhos amostrais diferentes (amostra total, amostra formada pelos países desenvolvidos, amostra formada pelos países subdesenvolvidos, amostra formada pelos países com rendimento baixo, amostra formada pelos países com rendimento médio baixo e amostra formada pelos países com rendimento médio alto).
- b) **Avaliação do modelo conceptual com o método baseado na matriz de covariâncias – CBSEM:** este eixo apresenta os resultados provenientes dos respectivos índices de ajustamento e testes de significância inerentes ao método CBSEM.
- c) **Avaliação do modelo conceptual com o método baseado na matriz de variâncias – PLS:** este eixo apresenta os resultados provenientes dos índices de consistência interna, fiabilidade individual (pesos factoriais standardizados) e de avaliação do modelo estrutural inerentes ao método PLS.
- d) **Comparação dos coeficientes estruturais entre os diferentes subgrupos:** neste eixo será comparada a magnitude dos coeficientes estruturais para os seis subgrupos de países e serão apresentados os resultados da análise multigrupos que permitem evidenciar se existem diferenças significativas a nível dos diferentes subgrupos.
- e) **Comparação das propriedades dos estimadores (precisão e eficiência) utilizados nos métodos CBSEM (ML) e VBSEM (PLS),** assentes no processo de reamostragem bootstrap através de uma simulação de Monte Carlo.

É importante salientar que, a base de dados edificada apresentou inicialmente alguns dados perdidos, fruto da ausência de determinados indicadores para certos países. Deste modo, cada

indicador e constructo foram cuidadosamente investigados com o propósito de identificar algum padrão subjacente aos dados perdidos. Como não foi identificado qualquer padrão, para contornar este problema recorreu-se ao método de imputação convencional, que consiste apenas na substituição de valores perdidos pelos valores estimados. Neste caso em particular, os valores perdidos foram substituídos pelo valor médio de cada indicador correspondente.

8.1. Eixo A: Análise Exploratória

8.1.1. Análise Estatística Multivariada

As tabelas 8.1.1 e 8.1.2 contêm as estatísticas relativas á análise multivariada da variável latente governança e qualidade de vida respectivamente, quer para a amostra total, quer para os restantes subgrupos. A primeira coluna contém a designação de cada amostra, da segunda á quinta colunas são apresentados os valores da simetria (sim) e achatamento (achat) multivariados acompanhados pelos respectivos valores de probabilidade resultantes da aplicação do teste de Mardia (Mardia, 2003), na sexta coluna é apresentado o valor do teste de *Shapiro Wilks* no âmbito da avaliação da normalidade multivariada, acompanhado pelo respectivo valor de probabilidade (sétima coluna).

Relativamente à variável latente governança, podemos verificar que nenhuma amostra preenche o pressuposto da normalidade multivariada, p.value (w) <0.01. Todos os subgrupos apresentam assimetria positiva, p.value (sim) <0.05 e caracter platicúrtico, p.value (achat) <0.05 (excepto as amostras relativas aos países com rendimento baixo e rendimento médio que não apresentam qualquer tipo de achatamento).

Tabela 8.1.1: estatísticas descritivas multivariadas das da amostra total e respectivos subgrupos - variável latente governança.

| | Teste de Mardia | | | Teste Shapiro | | |
|-----------------|-----------------|---------|--------|---------------|-------|---------|
| | Sim. | P.value | Achat. | P.value | W | P.value |
| A.Total* | 642.44 | 0.000 | 17.487 | 0.000 | 0.722 | 0.000 |
| PVD | 168.00 | 0.000 | 3.308 | 0.000 | 0.943 | 0.000 |
| PD | 500.25 | 0.000 | 15.93 | 0.000 | 0.734 | 0.000 |
| RB | 83.889 | 0.009 | 1.406 | 0.159 | 0.847 | 0.000 |
| RMB | 85.773 | 0.006 | 1.371 | 0.170 | 0.895 | 0.000 |
| RMA | 124.08 | 0.000 | 2.545 | 0.010 | 0.872 | 0.000 |

***A.total**=amostra total; **PVD**=amostra formada pelos países subdesenvolvidos; **PD**= amostra formada pelos países desenvolvidos; **RB**=amostra formada pelos países com rendimento baixo; **RMB**=amostra formada pelos países com rendimento médio baixo; **RMA**=amostra formada pelos países com rendimento médio alto.

Relativamente à variável latente qualidade, podemos verificar que nenhuma amostra preenche o pressuposto da normalidade multivariada, p.value (w) <0.01. Todas as amostras apresentam assimetria positiva, p.value (sim) <0.05 e caracter platicúrtico p.value (achat)

<0.05 (excepto a amostra relativa aos países com rendimento baixo que não apresenta qualquer tipo de achatamento).

Tabela 8.1.2: estatísticas descritivas multivariadas da amostra total e respectivos subgrupos - variável latente qualidade.

| | Teste de Mardia | | | Teste Shapiro | | |
|----------------|-----------------|---------|--------|---------------|-------|---------|
| | Sim. | P.value | Achat. | P.value | W | P.value |
| A.Total | | | | | | |
| PVD | 763.34 | 0.000 | 12.563 | 0.000 | 0.695 | 0.000 |
| PD | 749.70 | 0.000 | 14.147 | 0.000 | 0.451 | 0.000 |
| RB | 216.86 | 0.004 | 0.082 | 0.934 | 0.780 | 0.000 |
| RMB | 338.98 | 0.000 | 3.156 | 0.001 | 0.620 | 0.000 |
| RMA | 496.83 | 0.000 | 9.691 | 0.000 | 0.619 | 0.000 |

No âmbito da análise gráfica multivariada, as figuras seguintes exibem os gráficos quantil-quantil (Q-Q plot) relativos à amostra completa e restantes subgrupos. Olhando para os gráficos verifica-se que, em todos os casos, o quadrado da distância de Mahalanobis (D_i) se afasta de uma distribuição χ^2 caso os dados seguissem uma distribuição normal.

Figura 8.1.1: gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança (à esquerda) e Qualidade de Vida (à direita) - amostra total.




Figura 8.1.2: gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança (à esquerda) e Qualidade de Vida (à direita) – Países subdesenvolvidos.




Figura 8.1.3: gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança (à esquerda) e Qualidade de Vida (à direita) – Países desenvolvidos.

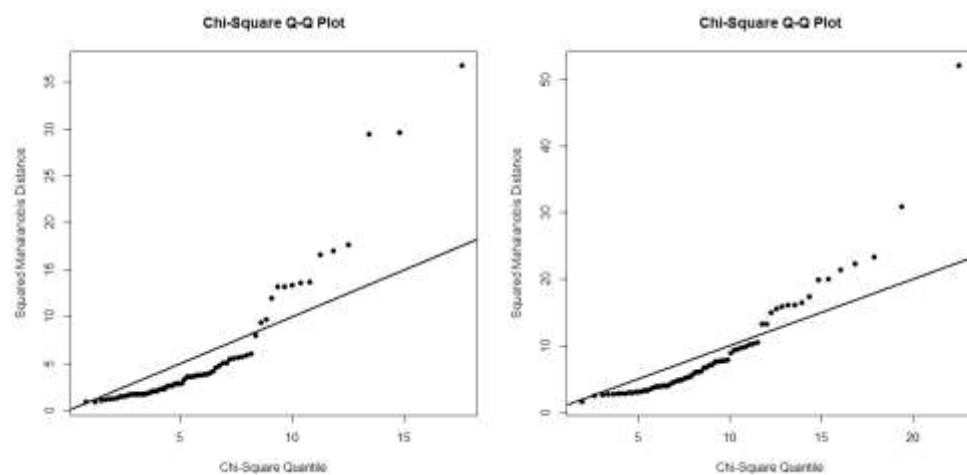


Figura 8.1.4: gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança (à esquerda) e Qualidade de Vida (à direita) – Países com rendimento baixo.




Figura 8.1.5: gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança (à esquerda) e Qualidade de Vida (à direita) – Países com rendimento médio baixo.





Figura 8.1.6: gráfico quantil-quantil da normalidade multivariada dos indicadores da variável latente Governança (à esquerda) e Qualidade de Vida (à direita) – Países com rendimento médio alto.



8.1.2. Análise estatística univariada

As tabelas 8.1.3 e 8.1.4 contêm as estatísticas descritivas dos indicadores das variáveis latentes governança e qualidade de vida respectivamente, quer para a amostra total, quer para os restantes subgrupos. A primeira coluna exibe o nome de cada indicador, a segunda coluna a dimensão de cada subgrupo, e da 3ª à 7ª colunas são apresentadas as estatísticas descritivas que permitem comparar os indicadores em cada subgrupo amostral, nomeadamente o valor mínimo (3ª coluna), 1ºquartil (4ªcoluna), mediana (5ªcoluna), média (6ª coluna) e o valor máximo (7ªcoluna). A análise gráfica, que ilustra os valores apresentados nas tabelas é representada através de caixas de bigodes.


Tabela 8.1.3: estatísticas descritivas dos indicadores da variável latente Governança (Gov).

| | N | Min. | 1ºquartil | Mediana | Media | 3ºquartil | Max. |
|------------|----------|-------------|------------------|----------------|--------------|------------------|-------------|
| va | | | | | | | |
| A.Total | 215 | 0.000 | 24.44 | 49.77 | 49.78 | 74.89 | 100.00 |
| PVD | 147 | 0.000 | 18.55 | 38.50 | 39.13 | 56.10 | 91.55 |
| PD | 68 | 0.000 | 66.32 | 80.04 | 72.81 | 92.12 | 100.00 |
| RB | 38 | 0.000 | 11.15 | 25.35 | 25.95 | 37.80 | 74.18 |
| RMB | 52 | 2.000 | 21.80 | 40.96 | 39.36 | 51.40 | 91.55 |
| RMA | 58 | 1.000 | 27.35 | 53.28 | 48.30 | 65.26 | 90.61 |
| sta | | | | | | | |
| A.Total | 215 | 0.000 | 24.50 | 50.00 | 49.55 | 75.00 | 100.0 |
| PVD | 147 | 0.000 | 17.00 | 35.00 | 38.31 | 56.00 | 100.0 |
| PD | 68 | 0.000 | 64.75 | 78.50 | 73.85 | 90.00 | 100.0 |
| RB | 38 | 0.000 | 8.500 | 19.00 | 23.47 | 33.00 | 76.00 |
| RMB | 52 | 0.000 | 18.00 | 33.50 | 37.52 | 56.25 | 96.00 |
| RMA | 58 | 4.000 | 29.00 | 48.50 | 49.29 | 70.00 | 100.0 |
| eg | | | | | | | |
| A.Total | 215 | 0.000 | 24.00 | 49.00 | 49.33 | 74.50 | 100.00 |
| PVD | 147 | 0.000 | 18.00 | 36.00 | 36.82 | 55.00 | 91.00 |
| PD | 68 | 0.000 | 71.75 | 83.50 | 76.37 | 92.00 | 100.00 |
| RB | 38 | 0.000 | 6.259 | 16.50 | 20.66 | 35.00 | 83.00 |
| RMB | 52 | 7.000 | 20.75 | 31.50 | 35.17 | 48.50 | 81.00 |
| RMA | 58 | 4.000 | 35.00 | 51.50 | 48.79 | 63.75 | 91.00 |
| qn | | | | | | | |
| A.Total | 215 | 0.000 | 24.00 | 49.00 | 49.32 | 74.50 | 100.0 |
| PVD | 147 | 0.000 | 18.00 | 36.00 | 36.76 | 54.00 | 90.00 |
| PD | 68 | 0.000 | 72.50 | 82.00 | 76.47 | 92.00 | 100.0 |
| RB | 38 | 0.000 | 10.50 | 19.50 | 24.18 | 36.75 | 84.00 |
| RMB | 52 | 4.000 | 22.75 | 32.50 | 35.13 | 48.25 | 83.00 |
| RMA | 58 | 2.000 | 29.50 | 53.50 | 46.19 | 64.25 | 90.00 |
| rl | | | | | | | |
| A.Total | 215 | 0.000 | 24.64 | 50.00 | 49.79 | 74.89 | 100.0 |
| PVD | 147 | 0.000 | 17.60 | 35.68 | 36.49 | 53.28 | 88.73 |
| PD | 68 | 0.000 | 71.27 | 82.63 | 78.53 | 92.00 | 100.0 |
| RB | 38 | 0.000 | 6.217 | 16.90 | 20.88 | 32.63 | 82.63 |
| RMB | 52 | 5.000 | 20.31 | 33.80 | 35.81 | 49.65 | 77.46 |
| RMA | 58 | 1.000 | 32.62 | 49.92 | 47.34 | 61.74 | 94.37 |
| cc | | | | | | | |
| A.Total | 215 | 0.000 | 24.00 | 49.00 | 49.35 | 75.50 | 100.0 |
| PVD | 147 | 0.000 | 18.00 | 36.00 | 37.04 | 54.50 | 88.00 |
| PD | 68 | 0.000 | 69.25 | 82.50 | 75.96 | 92.00 | 100.0 |
| RB | 38 | 0.000 | 9.000 | 20.00 | 23.47 | 36.00 | 78.00 |
| RMB | 52 | 4.000 | 20.25 | 33.50 | 36.35 | 51.25 | 77.00 |
| RMA | 58 | 2.000 | 30.50 | 50.00 | 47.14 | 63.75 | 88.00 |

Relativamente à variável voz e responsabilização (va) que mede a percepção da qualidade dos processos políticos, liberdades civis e direitos políticos em determinado país (numa escala de 0-100), verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (80.04), seguido dos países com rendimento médio alto (48.50), países com rendimento médio baixo (40.96), países subdesenvolvidos (38.50) e, finalmente os países com rendimento baixo (25.35). O valor mediano da amostra total situa-se nos 49.77.

A partir das caixas de bigodes da variável voz e responsabilização, representadas na figura 8.1.7, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 16 (Bahrein, va=14.08), 60 (Guiné Equatorial, va=2.82), 140 (Nova Caledónia, va=0.00), 158 (Qatar, va=21.60), 161 (Federação Russa, va=22.54), 166 (Arábia Saudita, va=3.29) e 203 (Emirados Árabes Unidos, va=20.00) constituem observações extremas (outliers).

Figura 8.1.7: Caixas de bigodes da variável manifesta voz e responsabilização (va), para os seis grupos de países- variável latente governança.




Relativamente à variável estabilidade política e ausência de violência (sta), que mede a percepção da probabilidade que o governo tem de cair (numa escala de 0-100), verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (78.50), seguido dos países com rendimento médio alto (53.28), países subdesenvolvidos (35.00), países com rendimento médio baixo (33.50) e, finalmente os países com rendimento baixo (19.00). O valor mediano da amostra total situa-se nos 50.00.

A partir das caixas de bigodes da variável estabilidade política e ausência de violência, representadas na figura 8.1.8, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 46 (Ilhas Cook, sta=0), nº 91 (Israel, sta=11), nº 161 (Federação Russa, sta=21) e nº 16 (Bahrein, sta=26), constituem observações extremas; e

relativamente ao grupo formado pelos países com rendimento baixo, a observação nº 189 (Taiwan, sta=76) constitui a única observação extrema.


Figura 8.1.8: Caixas de bigodes da variável manifesta estabilidade política e ausência de violência (sta), para os seis grupos de países- variável latente governança.



Relativamente à variável eficácia governamental (eg), que mede a eficácia inerente à capacidade governamental para implementar e produzir boas políticas e redistribuir os bens públicos (numa escala de 0-100), verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (83.50), seguido dos países com rendimento médio alto (51.50), países subdesenvolvidos (36.00), países com rendimento médio baixo (31.50) e, finalmente os países com rendimento baixo (16.50). O valor mediano da amostra total situa-se nos 49.00.

A partir das caixas de bigodes da variável eficácia governamental, representadas na figura 8.1.9, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 164 (São Marino, eg=0), nº 140 (Nova Caledónia, eg=0), nº 129 (Mónaco, eg=0), nº 60 (Guiné Equatorial, eg=3), e nº 46 (Ilhas Cook, eg=16), constituem observações extremas; e relativamente ao grupo formado pelos países com rendimento baixo, a observação nº 189 (Taiwan, eg=83) constitui a única observação extrema.


Figura 8.1.9: Caixas de bigodes da variável manifesta eficácia governamental (eg), para os seis grupos de países- variável latente governança.



Relativamente à variável qualidade regulatória (qr), que mede a percepção das dificuldades causadas pela regulação excessiva (numa escala de 0-100), verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (82.00), seguido dos países com rendimento médio alto (53.50), países subdesenvolvidos (36.00), países com rendimento médio baixo (32.50) e, finalmente os países com rendimento baixo (19.50). O valor mediano da amostra total situa-se nos 49.00.

A partir das caixas de bigodes da variável qualidade regulatória, representadas na figura 8.1.10, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 164 (São Marino, qr=0), nº 140 (Nova Caledónia, qr=0), nº 129 (Mónaco, qr=0), nº 60 (Guiné Equatorial, qr=8), e nº 46 (Ilhas Cook, qr=10), constituem observações extremas; e relativamente ao grupo formado pelos países com rendimento baixo, a observação nº 189 (Taiwan, qr=84) constitui a única observação extrema.


Figura 8.1.10: Caixas de bigodes da variável manifesta qualidade regulatória (qr), para os seis grupos de países- variável latente governança.



Relativamente à variável estado de direito (rl), que mede a confiança que os diversos agentes têm e a sua tendência de acordo com as regras da sociedade (numa escala de 0-100), verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (82.63), seguido dos países com rendimento médio alto (49.92), países subdesenvolvidos (36.00), países com rendimento médio baixo (33.80) e, finalmente os países com rendimento baixo (16.90). O valor mediano da amostra total situa-se nos 50.00.

A partir das caixas de bigodes da variável estado de direito, representadas na figura 8.1.11, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 164 (São Marino, rl=0), nº 140 (Nova Caledónia, rl=0), nº 60 (Guiné Equatorial, rl=11.27), nº 46 (Ilhas Cook, rl=18.78), e nº 161 (Federação Russa, rl=25.35), constituem observações extremas; e relativamente ao grupo formado pelos países com rendimento baixo, a observação nº 189 (Taiwan, rl=82.63) constitui a única observação extrema.

Figura 8.1.11: Caixas de bigodes da variável manifesta estado de direito (rl), para os seis grupos de países- variável latente governança.



Relativamente à variável controlo da corrupção (cc), que mede a percepção da corrupção nas diferentes nações (numa escala de 0-100), verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (82.50), seguido dos países com rendimento médio alto (50.00), países subdesenvolvidos (36.00), países com rendimento médio baixo (33.50) e, finalmente os países com rendimento baixo (20.00). O valor mediano da amostra total situa-se nos 49.00.

A partir das caixas de bigodes da variável controlo da corrupção, representadas na figura 8.1.12, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 164 (São Marinho, cc=0), nº 140 (Nova Caledónia, cc=0), nº 129 (Mónaco, cc=0), e nº 60 (Guiné Equatorial, cc=2), constituem observações extremas; e relativamente ao grupo formado pelos países com rendimento baixo, a observação nº 189 (Taiwan, rl=82.63) constitui a única observação extrema.

Figura 8.1.12: Caixas de bigodes da variável manifesta controlo da corrupção (cc), para os seis grupos de países- variável latente governança.





Tabela 8.1.4: estatística descritiva dos indicadores da variável latente Qualidade de Vida (QV).

| | N | Min. | 1ºquartil | Mediana | Media | 3ºquartil | Max. |
|------------|----------|-------------|------------------|----------------|--------------|------------------|-------------|
| LT | | | | | | | |
| A.Total | 215 | 0.176 | 0.764 | 0.910 | 0.832 | 0.980 | 1.000 |
| PVD | 147 | 0.176 | 0.650 | 0.816 | 0.772 | 0.935 | 1.000 |
| PD | 68 | 0.779 | 0.948 | 0.985 | 0.961 | 0.990 | 1.000 |
| RB | 38 | 0.176 | 0.439 | 0.597 | 0.621 | 0.810 | 0.994 |
| RMB | 52 | 0.378 | 0.637 | 0.791 | 0.759 | 0.920 | 1.000 |
| RMA | 58 | 0.404 | 0.864 | 0.923 | 0.891 | 0.960 | 0.996 |
| IMR | | | | | | | |
| A.Total | 215 | 0.000 | 8.485 | 22.87 | 35.58 | 54.16 | 185.40 |
| PVD | 147 | 0.000 | 20.34 | 34.90 | 47.73 | 69.74 | 185.40 |
| PD | 68 | 2.290 | 4.578 | 5.995 | 9.310 | 9.440 | 89.210 |
| RB | 38 | 6.290 | 60.68 | 77.38 | 80.46 | 95.95 | 160.40 |
| RMB | 52 | 0.000 | 25.05 | 41.04 | 45.34 | 61.67 | 102.40 |
| RMA | 58 | 4.960 | 14.42 | 20.55 | 27.86 | 29.55 | 185.40 |
| SN | | | | | | | |
| A.Total | 215 | 9.000 | 57.00 | 72.30 | 72.29 | 96.50 | 100.0 |
| PVD | 147 | 9.000 | 42.00 | 72.30 | 64.06 | 89.50 | 100.00 |
| PD | 68 | 70.00 | 72.32 | 99.51 | 90.12 | 100.0 | 100.0 |
| RB | 38 | 9.000 | 18.00 | 31.50 | 38.61 | 55.75 | 94.00 |
| RMB | 52 | 14.00 | 47.75 | 66.50 | 61.82 | 77.25 | 100.0 |
| RMA | 58 | 32.00 | 72.30 | 83.00 | 81.98 | 95.00 | 100.0 |
| EF | | | | | | | |
| A.Total | 215 | 0.400 | 1.700 | 2.960 | 2.958 | 3.000 | 10.70 |
| PVD | 147 | 0.400 | 1.308 | 2.106 | 2.212 | 2.964 | 5.700 |
| PD | 68 | 2.960 | 2.960 | 4.450 | 4.575 | 5.400 | 10.70 |
| RB | 38 | 0.600 | 1.000 | 1.250 | 1.547 | 1.775 | 3.600 |
| RMB | 52 | 0.400 | 1.275 | 1.800 | 2.073 | 2.960 | 5.500 |
| RMA | 58 | 1.001 | 2.200 | 2.900 | 2.744 | 2.960 | 5.700 |
| EPI | | | | | | | |
| A.Total | 215 | 32.10 | 51.50 | 58.60 | 58.57 | 64.40 | 93.50 |
| PVD | 147 | 32.10 | 49.10 | 58.60 | 55.96 | 60.45 | 86.40 |
| PD | 68 | 41.80 | 58.60 | 61.05 | 64.22 | 71.82 | 93.50 |
| RB | 38 | 32.10 | 43.92 | 50.05 | 49.38 | 58.20 | 68.20 |
| RMB | 52 | 33.70 | 48.30 | 58.60 | 54.97 | 58.85 | 69.10 |
| RMA | 58 | 36.30 | 58.60 | 59.65 | 61.42 | 67.22 | 86.40 |
| EFW | | | | | | | |
| A.Total | 215 | 3.980 | 6.620 | 6.820 | 6.816 | 7.220 | 8.960 |
| PVD | 147 | 3.980 | 6.345 | 6.820 | 6.585 | 6.820 | 7.930 |
| PD | 68 | 6.490 | 6.820 | 7.285 | 7.316 | 7.665 | 8.960 |
| RB | 38 | 4.260 | 5.568 | 6.415 | 6.265 | 6.820 | 7.750 |
| RMB | 52 | 4.660 | 6.412 | 6.820 | 6.644 | 6.820 | 7.420 |
| RMA | 58 | 3.980 | 6.695 | 6.820 | 6.732 | 6.958 | 7.930 |
| GDP | | | | | | | |
| A.Total | 215 | 244.8 | 1807 | 6912.0 | 14690 | 14160 | 163000 |
| PVD | 147 | 244.8 | 1219 | 3420.0 | 5029 | 7270 | 23730 |
| PD | 68 | 12760 | 14160 | 24920 | 35560 | 47480 | 163000 |
| RB | 38 | 244.8 | 481 | 634.8 | 2414 | 862.4 | 14160 |
| RMB | 52 | 927.8 | 1480 | 2439.0 | 3667 | 3416 | 14160 |
| RMA | 58 | 3309 | 5359 | 7028 | 7955 | 10250 | 14160 |

Relativamente à variável literacia (LT), que corresponde á percentagem da população com idade igual ou superior a 15 anos, capazes de ler e escrever compreensivelmente uma narração curta e simples no seu quotidiano, verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (0.985), seguido dos países com rendimento médio alto (0.923), países subdesenvolvidos (0.816), países com rendimento médio baixo (0.797) e, finalmente os países com rendimento baixo (0.597). O valor mediano da amostra total situa-se nos 0.910.

A partir das caixas de bigodes da variável literacia (LT), representadas na figura 8.1.13, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 8 (Antígua e Barbuda, LT=0.858), nº 60 (Guiné Equatorial, LT=0.857), nº 103 (Kuwait, LT=0.835), nº 211 (Ilhas Virgens, LT=0.810), nº203 (Emirados Árabes Unidos, LT=0.779) e nº 166 (Arabia Saudita, LT=0.788) constituem observações extremas; relativamente ao grupo formado pelos países subdesenvolvidos, a observação nº 143 (Níger, LT=0.176) constitui a única observação extrema; relativamente ao grupo formado pelos países com rendimento médio alto, os valores extremos correspondem às observações nº 197 (Tunísia, LT=0.743), nº 3 (Argélia, LT=0.700), nº 6 (Angola, LT=0.668) e nº 89 (Irake, LT=0.404). Relativamente à amostra total, os valores extremos correspondem às observações nº 120 (Mali, LT=0.464), nº 17 (Bangladesh, LT=0.431), nº 63 (Etiópia, LT=0.427), nº 29 (Guine Bissau, LT=0.424), nº 127 (Mauritânia, LT=0.417), nº 89 (Irake, LT= 0.404), nº 167 (Senegal, LT=0.402), nº 69 (Gambia, LT=0.401), nº 174 (Ilhas Salomão, LT=0.378), nº 1 (Afeganistão, LT=0.360), nº 78 (Guine, LT=0.359), nº 22 (Benim, LT=0.336), nº 170 (Serra Leoa, LT=0.296), nº 31 (Burkina Faso, LT=0.266), e nº 143 (Níger, LT=0.176).


Figura 8.1.13: Caixas de bigodes da variável manifesta taxa de literacia (LT), para os seis grupos de países- variável latente qualidade de vida.



Relativamente à variável Índice de mortalidade infantil (IMR) que traduz o número de óbitos de crianças, com menos de 1 ano, ocorridos durante um determinado período de tempo, (normalmente um ano) relativamente ao número de nados-vivos do mesmo período, sendo o valor estimado em número de crianças mortas por cada 1000 nados-vivos, verifica-se que o valor mediano mais elevado corresponde aos países com rendimento baixo (77.38), seguido dos países com rendimento médio baixo (41.04), países subdesenvolvidos (34.90), países com rendimento médio alto (20.55) e, finalmente os desenvolvidos (5.995). O valor mediano da amostra total situa-se nos 22.82.

A partir das caixas de bigodes da variável índice de mortalidade infantil, representadas na figura 8.1.14, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 8 (Antígua e Barbuda, IMR=18.86), nº 15 (Bahamas, IMR=24.68), nº 10 (Bahrein, IMR=16.80), nº 46 (Ilhas Cook, IMR=34.90), nº 74 (Gronelândia, IMR=15.40), nº 158 (Qatar, IMR=18.04), nº 161 (Federação Russa, IMR=15.03), nº 196 (Trindade e Tobago, IMR=25.05), e nº 60 (Guiné Equatorial, IMR=89.29), constituem observações extremas; relativamente ao grupo formado pelos países subdesenvolvidos, as observações nº 1 (Afeganistão, IMR=160.23), nº 170 (Serra Leoa, IMR=160.39) e nº 6 (Angola, IMR=185.23) constituem as três observações extremas; relativamente ao grupo formado pelos países com rendimento médio alto, os valores extremos correspondem às observações nº 68 (Gabão, IMR=54.51), nº 119 (Maldivas, IMR=54.89), nº 27 (Botswana, IMR=55.70), nº 176 (Africa do Sul, IMR=60.66), nº 199 (Turquemenistão, IMR=72.56), nº 14 (Azerbaijão, IMR=79.00) e nº 6 (Angola, IMR=185.36). Relativamente ao grupo formado pelos países com rendimento baixo, as observações nº 1 (Afeganistão, IMR=160.23), nº 170 (Serra Leoa, IMR=160.39) e nº 189 (Taiwan, IMR=6.29) constituem as três observações extremas. Relativamente à amostra total, os valores extremos correspondem às observações nº 109 (Libéria, IMR=155.76), nº 170 (Serra Leoa, IMR=160.39), nº 1 (Afeganistão, IMR=160.23), e nº 6 (Angola, IMR=185.23).


Figura 8.1.14: Caixas de bigodes da variável manifesta índice de mortalidade infantil (IMR), para os seis grupos de países- variável latente qualidade de vida.



Relativamente à variável facilidade de acesso ao saneamento básico (SN), que corresponde à percentagem da população com pelo menos um acesso adequado a infra-estruturas de eliminação de excreções, verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (99.10), seguido dos países com rendimento médio alto (81.98), países subdesenvolvidos (72.30), países com rendimento médio baixo (66.50) e, finalmente os países com rendimento baixo (31.50). O valor mediano da amostra total situa-se nos 72.30.

A partir das caixas de bigodes da variável facilidade de acesso ao saneamento básico, representadas na figura 8.1.15, verifica-se que, apenas o grupo formado pelos países com rendimento médio alto apresenta valores extremos, e que correspondem às observações nº 68 (Gabão, SN=33.00) e nº 135 (Namíbia, SN=32.00).

Figura 8.1.15: Caixas de bigodes da variável manifesta facilidade de acesso ao saneamento básico (SN), para os seis grupos de países- variável latente qualidade de vida.




Relativamente à variável pegada ecológica (EF), que corresponde à área territorial/terrestre necessária associada ao consumo da população e com capacidade para absorver todos os excedentes provenientes da mesma, verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (4.450), seguido dos países com rendimento médio alto (2.900), países subdesenvolvidos (2.100), países com rendimento médio baixo (1.800) e, finalmente os países com rendimento baixo (1.250). O valor mediano da amostra total situa-se nos 2.960.

A partir das caixas de bigodes da variável pegada ecológica, representadas na figura 8.1.16, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 158 (Qatar, EF=10.50), e nº 203 (Emirados Árabes Unidos, EF=10.70), constituem as duas observações extremas; relativamente ao grupo formado pelos países subdesenvolvidos, as observações nº 130 (Mongólia, EF=5.50) e nº 115 (Macedónia, EF=5.70) constituem as duas únicas observações extremas; relativamente ao grupo formado pelos países com rendimento

médio alto, os valores extremos correspondem às observações nº 125 (Mauritios, EF=4.30), nº 97 (Cazaquistão, EF=4.50), nº 118 (Malásia, EF=4.90), nº 115 (Macedónia, EF=5.70) e nº 6 (Angola, EF=1.00). Relativamente ao grupo formado pelos países com rendimento baixo, as observações nº 69 (Gâmbia, EF=3.40) e nº 137 (Nepal, EF=3.60) constituem as duas únicas observações extremas. Relativamente à amostra total, os valores extremos correspondem às observações nº 73 (Grécia, EF=5.40), nº 178 (Espanha, EF=5.40), nº 130 (Mongólia, EF=5.50), nº 106 (Letónia, EF=5.60), nº 146 (Noruega, EF=5.60), nº 115 (Macedónia, EF= 5.70), nº 52 (Republica checa, EF=5.70), nº 186 (Suécia, EF=5.90), nº 65 (Finlândia, EF=6.20), nº 138 (Holanda, EF=6.20), nº 103 (Kuwait, EF=6.30), nº 90 (Irlanda, LT=6.30), nº 12 (Austrália, EF=6.80), nº 35 (Canada, EF=7.00), nº 62 (Estónia, EF=7.90), nº 20 (Bélgica, EF=8.00), nº 205 (Estados Unidos, EF=8.00), nº 53 (Dinamarca, EF=8.40), nº 158 (Qatar, EF=10.50), e nº 203 (Emirados Árabes Unidos, EF=10.70).

Figura 8.1.16: Caixas de bigodes da variável manifesta pegada ecológica (EF), para os seis grupos de países- variável latente qualidade de vida.




Relativamente à variável índice de percepção ambiental (EPI), que corresponde à sensibilidade que cada país apresenta aos pressupostos assumidos pela estrutura do índice e da agregação dos 25 indicadores subjacentes, verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (61.50), seguido dos países com rendimento médio alto (59.65), países subdesenvolvidos (58.60) e países com rendimento médio baixo (58.60) e, finalmente os países com rendimento baixo (50.05). O valor mediano da amostra total situa-se nos 58.60.

A partir das caixas de bigodes da variável pegada ecológica, representadas na figura 8.1.17, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, a observações nº 85 (Islândia, EPI=93.5) constitui a única observação extrema; relativamente ao grupo formado pelos países subdesenvolvidos, as observações nº 150 (Panamá, EPI=71.4), nº 42 (Colômbia, EPI=76.8) e nº 50 (Cuba, EPI=78.1) constituem as três observações extremas; relativamente ao grupo formado pelos países com rendimento médio alto, os valores extremos correspondem

às observações nº 125 (Mauritios, EPI=80.6), nº 47 (Costa Rica, EPI=86.4), nº 6 (Angola, EPI=36.3), nº 199 (Turquemenistão, EPI=38.4), nº 89 (Irake, EPI=41.0) e nº 27 (Botswana, EPI=41.3). Relativamente à amostra total, os valores extremos correspondem às observações nº 186 (Suécia, EPI=86.0), nº 187 (Suíça, EPI=89.1), nº 47 (Costa Rica, EPI=86.4), nº 85 (Islândia, EPI=93.5) e nº 170 (Serra Leoa, EPI=32.10).

Figura 8.1.17: Caixas de bigodes da variável manifesta índice de percepção ambiental (EPI), para os seis grupos de países- variável latente qualidade de vida.




Relativamente à variável índice de liberdade económica mundial (EFW), verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (7.285), seguido dos países com rendimento médio alto (6.280), países subdesenvolvidos (6.280), países com rendimento médio baixo (6.280) e, finalmente os países com rendimento baixo (6.415). O valor mediano da amostra total situa-se igualmente nos 6.820.

A partir das caixas de bigodes da variável índice de liberdade económica mundial, representadas na figura 8.1.18, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 171 (Singapura, EFW=8.76), constitui a única observação extrema; relativamente ao grupo formado pelos países subdesenvolvidos, os valores extremos correspondem às observações nº 153 (Peru, EFW=7.61), nº 96 (Jordânia, EFW=7.65), nº 147 (Omao, EFW=7.65), nº 189 (Taiwan, EFW=7.75), nº 125 (Mauritios, EFW=7.93), nº 6 (Angola, EFW=5.05), nº 32 (Burundi, EFW=5.38), nº 38 (Republica Central Africana, EFW=5.34), nº 39 (Chade, EFW=5.27), nº 44 (Rep. Dem. Congo, EFW=5.03), nº 45 (Rep. Congo, EFW=4.66), nº 79 (Guine Bissau, EFW=5.24), nº 133 (Moçambique, EFW=5.41), nº 134 (Myanmar, EFW=4.29), nº 143 (Niger, EFW=5.54), nº 194 (Togo, EFW=5.54), nº 209 (Venezuela, EFW=3.98) e nº 215 (Zimbabwe, EFW=4.26); relativamente ao grupo formado pelos países com rendimento médio alto, os valores extremos correspondem às observações nº 125 (Mauritios, EFW=7.93), nº 96 (Jordânia, EFW=7.65), nº 131 (Montenegro, EFW=7.57), nº 150 (Panamá, EFW=7.46), nº 153 (Peru, EFW=7.61), nº 160 (Roménia, EFW=7.43), nº 3 (Algéria, EFW=5.33), nº 6 (Angola,

EFW=5.05), nº 209 (Venezuela, EFW=3.98), nº 14 (Azerbaijão, EFW=6.09), nº 41 (China, EFW=6.37), nº 57 (Equador, EFW=5.80), nº 68 (Gabão, EFW=5.85) e nº 88 (Irão, EFW=6.29). Relativamente ao grupo formado pelos países com rendimento médio baixo, os valores extremos correspondem às observações nº 45 (Rep. Congo, EFW=4.66), nº 48 (Costa do Marfim, EFW=5.72), nº 108 (Lesoto, EFW=5.77), e nº 124 (Mauritânia, EFW=5.62). Relativamente à amostra total, os valores extremos correspondem às observações nº 141 (Nova Zelândia, EFW=8.46), nº 171 (Singapura, EFW=8.76), nº 187 (Suíça, EFW=8.29), nº 83 (Hong Kong, EFW=8.96), nº 3 (Argélia, EFW=5.33), nº 6 (Angola, EFW= 5.05), nº 32 (Burundi, EFW=5.38), nº 38 (Rep. Central Africana, EFW=5.38), nº 194 (Togo, EFW=5.54), nº 39 (Chade, EFW=5.27), nº 44 (Rep. Dem. Congo, EFW=5.03), nº 45 (Rep. Congo, EFW=4.60), nº 48 (Costa do Marfim, EFW=5.73), nº 134 (Myanmar, EFW=4.29), nº 215 (Zimbabwe, EFW=4.26), nº 63 (Etiópia, EFW=5.65), nº 79 (Guiné Bissau, EFW=5.24), nº 108 (Lesoto, EFW=5.77), nº 124 (Mauritânia, EFW=5.62), e nº 143 (Níger, EFW=5.54).

Figura 8.1.18: Caixas de bigodes da variável manifesta índice de liberdade económica mundial (EFW), para os seis grupos de países- variável latente qualidade de vida.




Relativamente à variável produto interno bruto (GDP), verifica-se que o valor mediano mais elevado corresponde aos países desenvolvidos (24920), seguido dos países com rendimento médio alto (7028), países subdesenvolvidos (3420), países com rendimento médio baixo (2439) e, finalmente os países com rendimento baixo (6348). O valor mediano da amostra total situa-se nos 6912.

A partir das caixas de bigodes da variável produto interno bruto, representadas na figura 8.1.19, verifica-se que, relativamente ao grupo formado pelos países desenvolvidos, as observações nº 113 (Luxemburgo, GDP=114210.82), nº 129 (Mónaco, GDP=163025.86) e nº 149 (Noruega, GDP=99143.17) constituem as três observações extremas; relativamente ao

grupo formado pelos países subdesenvolvidos, a observação nº 147 (Omã, GDP=23730) constitui a única observação extrema; relativamente ao grupo formado pelos países com rendimento médio baixo, os valores extremos correspondem às observações nº 46 (Ilhas Cook, GDP=14160), nº 123 (Martinique, GDP=14160), nº 136 (Nauru, GDP=14160), nº 159 (Reunião, GDP=14160), nº 188 (Síria, GDP=14160), e nº 212 (Gaza, GDP=14160). Relativamente ao grupo formado pelos países com rendimento baixo, os valores extremos correspondem às observações nº 100 (Rep. Dem. Coreia, GDP=14160), nº 134 (Myanmar, GDP=14160), nº 145 (NIUE, GDP=14160), nº 175 (Somália, GDP=14160), nº 189 (Taiwan, GDP=14160), e nº 104 (Rep. Kirzigistao, GDP=1123.88). Relativamente à amostra total, os valores extremos correspondem às observações nº 12 (Austrália, GDP=62002.84), nº 13 (Áustria, GDP=49581.46), nº 23 (Bermuda, GDP=86071.62), nº 35 (Canadá, GDP=51554.06), nº 53 (Dinamarca, GDP=59881.01), nº 65 (Finlândia, GDP= 48842.96), nº 66 (França, GDP=42521.81), nº 90 (Irlanda, GDP=48248.23), nº 103 (Kuwait, GDP=56514.16), nº 113 (Luxemburgo, GDP=114210.82), nº 114 (Macau, GDP=67359.47), nº 129 (Mónaco, GDP=163025.86), nº 138 (Holanda, GDP=50085.06), nº 146 (Noruega, GDP=99143.17), nº 158 (Qatar, GDP=90523.53), nº 171 (Singapura, GDP=47268.76), nº 186 (Suécia, GDP=57071.20), nº 187 (Suíça, GDP=83325.93), nº 205 (Estados Unidos, GDP=48112.60).

Figura 8.1.19: Caixas de bigodes da variável manifesta produto interno bruto (GDP), para os seis grupos de países- variável latente qualidade de vida.



8.2. Eixo B: Avaliação do modelo conceptual com o método baseado na matriz de covariâncias – CBSEM.

O modelo conceptual em estudo (representado na figura 7.4) foi avaliado em duas etapas. A estimação através do método da máxima verosimilhança (CBSEM) foi realizado com recurso ao pacote *lavaan* desenvolvido para o *software* R (versão 0.5; Rosseel, 2012). A qualidade de ajustamento do modelo de medida (etapa 1) e do modelo estrutural (etapa 2) foi feito de acordo com alguns índices de qualidade de ajustamento e respectivos valores de referência descritos na tabela 3.4, a saber: χ^2/df , CFI, TLI; RMSEA, $P[RMSEA < 0.05]$ e SRMR.

A qualidade do ajustamento local foi avaliada através da fiabilidade individual dos indicadores (pesos factoriais estandardizados) e a significância das trajectórias estruturais e de medida foi avaliada com um teste Z aos rácios críticos (CR). A significância das trajectórias de medida foi também avaliada com recurso ao método de reamostragem *bootstrap* (com 1000 subamostras), utilizado para realizar o cálculo do valor de probabilidade do teste estatístico Z. consideraram-se significativas as trajectórias com $p < 0.1$.

8.2.1. Modelo de Medida e Estrutural com método CBSEM - Amostra total ($n=215$)

A tabela 8.2.1 apresenta os resultados da estimação com o método CBSEM para $N=215$. A primeira coluna contém o nome dos indicadores constituintes das respectivas variáveis latentes, a segunda coluna os coeficientes de regressão não estandardizados (Estimate), a terceira coluna apresenta o erro padrão associado ao valor do coeficiente de regressão (E.P), a quarta e quinta coluna contém o valor relativo à estatística de teste (C.R) e o correspondente valor de probabilidade (p.value). A sexta coluna contém valor de probabilidade proveniente da aplicação do método bootstrap (P.boot) e finalmente a sétima coluna, o valor do peso factorial estandardizado de cada variável (P.F).

O modelo factorial confirmatório da variável latente governança, ajustado a uma amostra de 215 países apresenta índices de qualidade de ajustamento considerados bons ($\chi^2/df=6.42$; $P[\chi^2 < 0.05]$; CFI= 0.981; TLI= 0.953) e moderados (RMSEA=0.159; $P[RMSEA < 0.05] < 0.000$; SRMR= 0.018) em suporte da validade factorial do modelo em causa. A partir da tabela 8.2.1, verifica-se que todas as trajectórias são positivas e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap. Todos os indicadores da variável latente governança apresentam pesos factoriais elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$) em suporte da validade factorial da variável latente governança. O indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.958$) o que significa que 92% (0.958^2) da variabilidade deste indicador é explicado pela variável latente governança.

Tabela 8.2.1: Estatísticas da análise factorial confirmatória da variável latente Governança – amostra total (N=215)

| | Estimate | E.P | C.R | P(> z) | P.Boot | P. F |
|------------|-----------------|------------|------------|-------------------|---------------|-------------|
| <i>va</i> | 1.00 | | | | | 0.827 |
| <i>sta</i> | 0.95 | 0.07 | 13.89 | 0.000 | 0.000 | 0.786 |
| <i>eg</i> | 1.14 | 0.06 | 18.93 | 0.000 | 0.000 | 0.945 |
| <i>qn</i> | 1.10 | 0.06 | 17.31 | 0.000 | 0.000 | 0.900 |
| <i>rl</i> | 1.15 | 0.06 | 19.41 | 0.000 | 0.000 | 0.958 |
| <i>cc</i> | 1.15 | 0.06 | 19.11 | 0.000 | 0.000 | 0.950 |

A partir da tabela 8.2.2 verifica-se que o modelo factorial confirmatório da variável qualidade, ajustado a uma amostra de 215 países revelou uma qualidade de ajustamento muito boa ($X^2/df=0.975$; $P[X^2<0.05]$; CFI=1.000; TLI=1.000; RMSEA=0.000; $P[RMSEA<0.05]=0.833$; SRMR=0.055) em suporte da validade factorial do modelo em causa. Verifica-se também que, todas as trajectórias são positivas (excepto o indicador relativo ao índice de mortalidade infantil (IMR) cujo efeito esperado é negativo, uma vez que um índice de mortalidade infantil negativo corresponde a uma melhor qualidade de vida das populações) e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap. Todos os indicadores da variável latente qualidade apresentam pesos factoriais elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$) em suporte da validade factorial da variável latente qualidade. O indicador qualidade de saneamento básico (SN) apresenta o maior peso factorial estandardizado ($P.F=0.866$) o que significa que 75% (0.866^2) da variabilidade deste indicador é explicado pela variável latente qualidade.

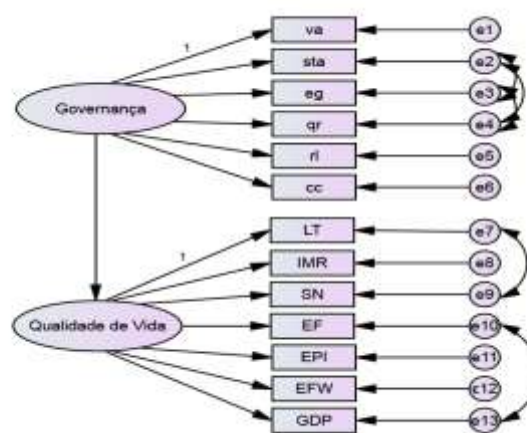
Tabela 8.2.2: Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida – amostra total (N=215)

| | Estimate | E.P | C.R | P(> z) | P.Boot | P. F |
|------------|-----------------|------------|------------|-------------------|---------------|-------------|
| <i>LT</i> | 1.000 | | | 0.000 | 0.000 | 0.797 |
| <i>IMR</i> | -1.076 | 0.077 | -14.04 | 0.000 | 0.000 | -0.858 |
| <i>SN</i> | 1.086 | 0.077 | 14.19 | 0.000 | 0.000 | 0.866 |
| <i>EF</i> | 0.808 | 0.082 | 9.820 | 0.000 | 0.000 | 0.644 |
| <i>EPI</i> | 0.855 | 0.081 | 10.51 | 0.000 | 0.000 | 0.682 |
| <i>EFW</i> | 0.773 | 0.083 | 9.32 | 0.000 | 0.000 | 0.616 |
| <i>GDP</i> | 0.679 | 0.084 | 8.03 | 0.000 | 0.000 | 0.541 |

Relativamente ao modelo estrutural, ou seja, aquele em que é aprofundada a relação de dependência entre as duas variáveis latentes (Governança-> Qualidade de Vida) ajustado a uma amostra de 215 países, verifica-se que a trajectória entre os factores se revelou positiva e estatisticamente significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$ ($\beta_{Gov-QV}=0.722$; SE=0.070; $p=0.000$) a par com uma medíocre qualidade de ajustamento do modelo ($X^2/df=5.93$; $P[X^2<0.05]<0.001$; CFI= 0.884; TLI= 0.858; RMSEA= 0.152; $P[RMSEA<0.05]<0.001$; SRMR= 0.064).

Contudo, depois de correlacionados os erros de medida dos indicadores 2, 3, 4, pertencentes à variável latente governança e os erros de medida 7, 9, 10 e 13 pertencentes à variável latente qualidade, foi possível obter uma qualidade de ajustamento significativamente melhor ($X^2/df=3.43$; $P[X^2<0.05]<0.001$; CFI= 0.947; TLI= 0.930; RMSEA= 0.106; $P[RMSEA<0.05]<0.001$; SRMR= 0.056) em suporte da validade estrutural do modelo em causa.

Figura 8.2.1: modelo estrutural CBSEM com 8 resíduos correlacionados (ϵ_2 e ϵ_4 , ϵ_3 e ϵ_4 , ϵ_7 e ϵ_9 , ϵ_{10} e ϵ_{13}) - Amostra total (N=215).



8.2.2. Modelo de medida e estrutural com método CBSEM - Países subdesenvolvidos (N=147).

O modelo factorial confirmatório da variável latente governança, ajustado a uma amostra de 147 países (grupo formado pelos países subdesenvolvidos) apresenta índices de qualidade de ajustamento considerados bons ($X^2/df=2.83$; $P[x^2<0.05]$; CFI= 0.987; TLI= 0.968) e moderados (RMSEA=0.159; $P[RMSEA<0.05]<0.000$; SRMR= 0.022) em suporte da validade factorial do modelo em causa. A partir da tabela 8.2.3, verifica-se que todas as trajectórias são positivas e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap. Todos os indicadores da variável latente governança apresentam pesos factoriais elevados ($P.F>0.5$) e fiabilidades individuais adequadas ($P.F^2>0.25$) em suporte da validade factorial da variável latente governança. O indicador estado de direito (rl) apresenta o maior peso factorial estandardizado

(P.F=0.967) o que significa que 94% (0.967²) da variabilidade deste indicador é explicado pela variável latente governança.

Tabela 8.2.3: Estatísticas da análise factorial confirmatória da variável latente Governança - Países subdesenvolvidos (N=147)

| | Estimate | S.E | C.R | P(> z) | P.boot | P.F |
|------------|-----------------|------------|------------|-------------------|---------------|------------|
| <i>va</i> | 1.000 | | | | | 0.774 |
| <i>sta</i> | 0.987 | 0.105 | 9.440 | 0.000 | 0.000 | 0.723 |
| <i>eg</i> | 1.043 | 0.087 | 11.926 | 0.000 | 0.000 | 0.871 |
| <i>qn</i> | 0.907 | 0.091 | 9.955 | 0.000 | 0.000 | 0.755 |
| <i>rl</i> | 1.169 | 0.085 | 13.668 | 0.000 | 0.000 | 0.967 |
| <i>cc</i> | 1.117 | 0.087 | 12.805 | 0.000 | 0.000 | 0.918 |

A partir da tabela 8.2.4 verifica-se que o modelo factorial confirmatório da variável qualidade de vida, ajustado a uma amostra de 147 países (grupo formado pelos países subdesenvolvidos) revelou uma qualidade de ajustamento muito boa ($X^2/df=11.947$; $P[X^2>0.2]$; CFI=1.000; TLI=1.000; RMSEA= 0.000; $P[RMSEA<0.05]<0.858$; SRMR= 0.033) em suporte da validade factorial do modelo em causa. A partir da tabela x, verifica-se que todas as trajectórias são positivas (excepto o indicador relativo ao índice de mortalidade infantil - IMR) e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap. Todos os indicadores da variável latente qualidade apresentam pesos factoriais elevados (P.F> 0.5) e fiabilidades individuais adequadas (excepto o indicador referente à liberdade económica mundial- EFW, cujo peso factorial estandardizado é igual a 0.466) em suporte da validade factorial da variável latente qualidade. O indicador qualidade de saneamento básico (SN) apresenta o maior peso factorial estandardizado (P.F=0.849) o que significa que 72% (0.849²) da variabilidade deste indicador é explicado pela variável latente qualidade.

Tabela 8.2.4: Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países subdesenvolvidos (N=147).

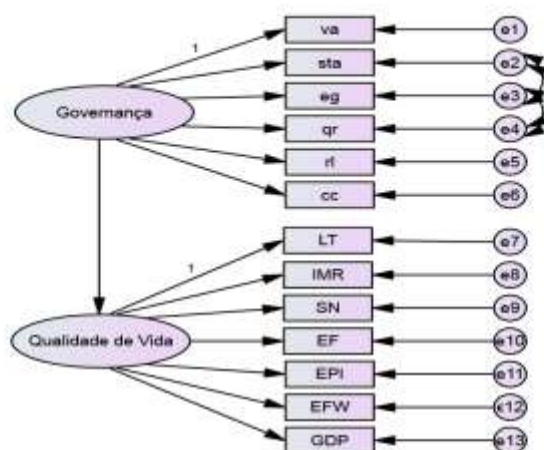
| | Estimate | S.E | C.R | P(> z) | P.boot | P.F |
|------------|-----------------|------------|------------|-------------------|---------------|------------|
| <i>LT</i> | 1.000 | | | | | 0.759 |
| <i>IMR</i> | -1.050 | 0.104 | -10.070 | 0.000 | 0.000 | -0.826 |
| <i>SN</i> | 1.091 | 0.105 | 10.345 | 0.000 | 0.000 | 0.849 |
| <i>EF</i> | 0.437 | 0.063 | 6.964 | 0.000 | 0.000 | 0.587 |
| <i>EPI</i> | 0.754 | 0.097 | 7.794 | 0.000 | 0.000 | 0.652 |
| <i>EFW</i> | 0.548 | 0.101 | 5.450 | 0.000 | 0.000 | 0.466 |
| <i>GDP</i> | 0.168 | 0.023 | 7.347 | 0.000 | 0.000 | 0.617 |

Relativamente ao modelo estrutural, (Governança-> Qualidade de Vida) ajustado a uma amostra de 147 países (grupo formado pelos países subdesenvolvidos), verifica-se que a

trajectória entre os factores se revelou positiva e estatisticamente significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$ ($\beta_{\text{Gov-QV}}=0.708$; $\text{SE}=0.118$; $p=0.000$) a par com uma medíocre qualidade de ajustamento do modelo ($X^2/\text{df}=3.67$; $P[X^2<0.05]<0.001$; $\text{CFI}=0.875$; $\text{TLI}=0.848$; $\text{RMSEA}=0.135$; $P[\text{RMSEA}<0.05]<0.001$; $\text{SRMR}=0.080$).

Contudo, depois de correlacionados os erros de medida dos indicadores 2, 3, 4, pertencentes à variável latente governança, foi possível obter uma qualidade de ajustamento significativamente melhor ($X^2/\text{df}=2.30$; $P[X^2<0.05]<0.001$; $\text{CFI}=0.942$; $\text{TLI}=0.925$; $\text{RMSEA}=0.094$; $P[\text{RMSEA}<0.05]<0.001$; $\text{SRMR}=0.074$) em suporte da validade estrutural do modelo em causa.

Figura 8.2.2: modelo estrutural CB-SEM com 6 resíduos correlacionados (ϵ_2 e ϵ_3 , ϵ_2 e ϵ_4 , ϵ_3 e ϵ_4) – Países subdesenvolvidos ($N=147$).



8.2.3. Modelo de medida e estrutural com método CBSEM - Países desenvolvidos ($N=68$).

O modelo factorial confirmatório da variável latente governança, ajustado a uma amostra de 68 países (grupo formado pelos países desenvolvidos) apresenta índices de qualidade de ajustamento considerados bons ($X^2/\text{df}=2.96$; $P[X^2<0.05]$; $\text{CFI}=0.975$; $\text{TLI}=0.937$) e moderados ($\text{RMSEA}=0.170$; $P[\text{RMSEA}<0.05]<0.002$; $\text{SRMR}=0.058$) em suporte da validade factorial do modelo em causa. A partir da tabela 8.2.5, verifica-se que todas as trajectórias são positivas e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap. Todos os indicadores

da variável latente governança apresentam pesos factoriais elevados ($P.F > 0.5$) e fiabilidade individuais adequadas ($P.F^2 > 0.25$) em suporte da validade factorial da variável latente governança. O indicador eficácia da governança (eg) apresenta o maior peso factorial estandardizado ($P.F = 0.990$) o que significa que 98% (0.990^2) da variabilidade deste indicador é explicado pela variável latente governança.

Tabela 8.2.5: Estatísticas da análise factorial confirmatória da variável latente Governança - Países desenvolvidos (N=68).

| | Estimate | S.E | C.R | P(> z) | P.boot | P.F |
|------------|-----------------|------------|------------|-------------------|---------------|------------|
| <i>va</i> | 1.00 | | | | | 0.616 |
| <i>sta</i> | 0.680 | 0.176 | 3.868 | 0.000 | 0.001 | 0.510 |
| <i>eg</i> | 1.483 | 0.234 | 6.349 | 0.000 | 0.000 | 0.990 |
| <i>qn</i> | 1.429 | 0.228 | 6.258 | 0.000 | 0.000 | 0.965 |
| <i>rl</i> | 0.997 | 0.181 | 5.515 | 0.000 | 0.000 | 0.799 |
| <i>cc</i> | 1.403 | 0.229 | 6.126 | 0.000 | 0.000 | 0.933 |

A partir da tabela 8.2.6 verifica-se que o modelo factorial confirmatório da variável qualidade de vida, ajustado a uma amostra de 68 países (grupo formado pelos países desenvolvidos) revelou uma qualidade de ajustamento fraca ($X^2/df=4.63$; $P[X^2 < 0.05]$; CFI=0.753; TLI=0.629; RMSEA=0.141; $P[RMSEA < 0.05] < 0.013$; SRMR=0.104) não suportando a validade factorial do modelo em causa. Verifica-se também que excepto os indicadores relativos à qualidade de literacia (LT, $P.F=0.425$), pegada ecológica (E.F, $P.F=4.33$) e ao produto interno bruto (GDP, $P.F=0.418$), todos os restantes indicadores da variável latente qualidade de vida apresentam pesos factoriais elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$). O indicador qualidade de saneamento básico (SN) apresenta o maior peso factorial estandardizado ($P.F=0.849$) o que significa que 72% (0.849^2) da variabilidade deste indicador é explicado pela variável latente qualidade. Não obstante, verifica-se que todas as trajectórias são positivas (excepto o indicador relativo ao índice de mortalidade infantil - IMR) mas estatisticamente não significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$ (resultados demonstrados pelo valor de probabilidade obtido pelo método bootstrap), levando a concluir que o submodelo de medida pode não ser adequado, pondo em causa o significado do modelo estrutural em estudo.

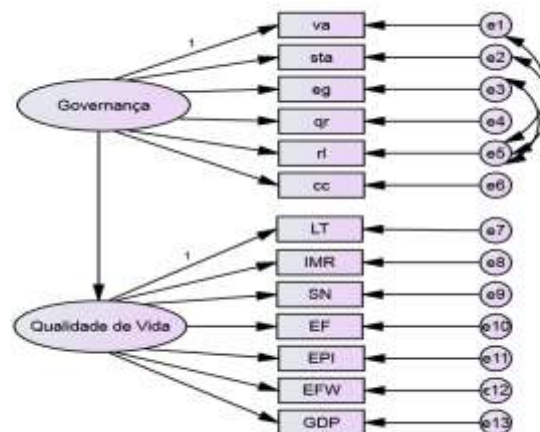
Tabela 8.2.6: Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países desenvolvidos (N=68).

| | Estimate | S.E | C.R | P(> z) | P.boot | P.F |
|------------|-----------------|------------|------------|-------------------|---------------|------------|
| <i>LT</i> | 1.000 | | | | | 0.425 |
| <i>IMR</i> | -1.504 | 0.579 | -2.596 | 0.009 | 0.441 | -0.542 |
| <i>SN</i> | 2.538 | 0.929 | 2.732 | 0.006 | 0.628 | 0.617 |
| <i>EF</i> | 3.929 | 1.696 | 2.317 | 0.021 | 0.490 | 0.433 |
| <i>EPI</i> | 5.259 | 1.894 | 2.776 | 0.005 | 0.671 | 0.650 |
| <i>EFW</i> | 3.221 | 1.274 | 2.528 | 0.011 | 0.670 | 0.511 |
| <i>GDP</i> | 4.630 | 2.040 | 2.270 | 0.023 | 0.583 | 0.418 |

Relativamente ao modelo estrutural, (Governança-> Qualidade de Vida) ajustado a uma amostra de 68 países (grupo formado pelos países desenvolvidos), verifica-se que a trajetória entre os factores se revelou positiva e estatisticamente significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$ ($\beta_{\text{Gov-QV}} = 0.160$; $SE = 0.055$; $p=0.004$) a par com uma medíocre qualidade de ajustamento do modelo ($X^2/df=3.55$; $P[X^2<0.05]<0.001$; $CFI= 0.754$; $TLI= 0.700$; $RMSEA= 0.194$; $P[RMSEA<0.05]< 0.001$; $SRMR= 0.119$).

Contudo, depois de correlacionados os erros de medida dos indicadores 2, 3, 4, pertencentes à variável latente governança, foi possível obter uma qualidade de ajustamento significativamente melhor ($X^2/df=2.86$; $P[X^2<0.05]<0.001$; $CFI= 0.828$; $TLI= 0.780$; $RMSEA= 0.166$; $P[RMSEA<0.05]< 0.001$; $SRMR= 0.114$) em suporte da validade estrutural do modelo em causa.

Figura 8.2.3: modelo estrutural CBSEM com 6 resíduos correlacionados (ϵ_2 e ϵ_5 , ϵ_2 e ϵ_3 , ϵ_3 e ϵ_5) – Países desenvolvidos (N=68).



8.2.4. Modelo de medida e estrutural com método CBSEM - Países com rendimento baixo (N=38)

O modelo factorial confirmatório da variável latente governança, ajustado a uma amostra de 38 países (grupo formado pelos países com rendimento baixo) apresenta índices de qualidade de ajustamento considerados bons ($X^2/df=1.61$; $P[X^2<0.05]$; CFI=0.977; TLI=0.957) e moderados (RMSEA=0.127; $P[RMSEA<0.05]>0.1$; SRMR= 0.034) em suporte da validade factorial do modelo em causa. A partir da tabela 8.2.7, verifica-se que todas as trajectórias são positivas e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap. Todos os indicadores da variável latente governança apresentam pesos factoriais elevados ($P.F>0.5$) e fiabilidade individuais adequadas ($P.F^2>0.25$) em suporte da validade factorial da variável latente governança. O indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.946$) o que significa que 89% (0.946^2) da variabilidade deste indicador é explicado pela variável latente governança.

Tabela 8.2.7: Estatísticas da análise factorial confirmatória da variável latente Governança - Países com rendimento baixo (N=38).

| | Estimate | S.E | C.R | P(> z) | P.Boot | P. F |
|-----|----------|-------|-------|---------|--------|-------|
| va | 1.00 | | | | | 0.715 |
| sta | 1.025 | 0.247 | 4.148 | 0.000 | 0.003 | 0.681 |
| eg | 1.369 | 0.240 | 5.703 | 0.000 | 0.003 | 0.930 |
| qn | 1.364 | 0.245 | 5.580 | 0.000 | 0.004 | 0.910 |
| rl | 1.387 | 0.239 | 5.794 | 0.000 | 0.001 | 0.946 |
| cc | 1.272 | 0.249 | 5.118 | 0.000 | 0.015 | 0.837 |


A partir da tabela 8.2.8 verifica-se que o modelo factorial confirmatório da variável qualidade de vida, ajustado a uma amostra de 38 países (grupo formado pelos países com rendimento baixo) revelou uma qualidade de ajustamento moderada ($X^2/df=3.90$; $P[X^2>0.2]$; CFI=0.963; TLI=0.944) e fraca RMSEA= 0.065; $P[RMSEA<0.05]= 0.388$; SRMR= 0.077) em suporte da validade factorial do modelo em causa. Verifica-se também que todas as trajectórias são positivas (excepto o indicador relativo ao índice de mortalidade infantil - IMR) e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap. Todos os indicadores da variável latente qualidade apresentam pesos factoriais elevados ($P.F> 0.5$) e fiabilidades individuais adequadas ($P.F^2> 0.25$) em suporte da validade factorial da variável latente qualidade. O indicador qualidade de saneamento básico (SN) apresenta o maior peso factorial estandardizado ($P.F=0.776$) o que significa que 60% (0.776^2) da variabilidade deste indicador é explicado pela variável latente qualidade.

Tabela 8.2.8: Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países com rendimento baixo (N=38).

| | Estimate | S.E | C.R | P(> z) | P.Boot | P. F |
|-----|----------|-------|--------|---------|--------|--------|
| LT | 1.000 | | | | | 0.762 |
| IMR | -0.798 | 0.199 | -4.009 | 0.000 | 0.002 | -0.704 |
| SN | 0.816 | 0.187 | 4.359 | 0.000 | 0.000 | 0.776 |
| EF | 0.199 | 0.095 | 2.106 | 0.035 | 0.016 | 0.371 |
| EPI | 0.474 | 0.153 | 3.093 | 0.002 | 0.003 | 0.542 |
| EFW | 0.452 | 0.225 | 2.012 | 0.044 | 0.094 | 0.355 |
| GDP | 0.142 | 0.042 | 3.410 | 0.001 | 0.012 | 0.597 |

Relativamente ao modelo estrutural, (Governança-> Qualidade de Vida) ajustado a uma amostra de 38 países (grupo formado pelos países com rendimento baixo), verifica-se que a trajetória entre os factores se revelou positiva mas estatisticamente não significativa (valores de erros padrão dos coeficientes da ordem das estimativas dos coeficientes, ou superiores, são indicadores de problemas com as variáveis) para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$ ($\beta_{\text{Gov-QV}} = 0.102$; SE= 0.389; $p= 0.794$) a par com uma medíocre qualidade de ajustamento do modelo ($X^2/\text{df}=1.35$; $P[X^2<0.05]< 0.032$; CFI= 0.919; TLI= 0.901; RMSEA= 0.096; $P[\text{RMSEA}<0.05]< 0.098$; SRMR= 0.118).

Figura 8.2.4: modelo estrutural com método CBSEM - Países com rendimento baixo (N=38).



8.2.5. Modelo de medida e estrutural com método CBSEM - Países com rendimento médio-baixo (N=52)

O modelo factorial confirmatório da variável latente governança, ajustado a uma amostra de 52 países (grupo formado pelos países com rendimento médio baixo) apresenta índices de qualidade de ajustamento considerados muito bons ($X^2/df=1.02$; $P[X^2<0.05]$; CFI=0.999; TLI=0.999; RMSEA=0.02; $P[RMSEA<0.05]=0.493$; SRMR= 0.034) em suporte da validade factorial do modelo em causa. A partir da tabela 8.2.9, verifica-se que todas as trajectórias são positivas e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap. Todos os indicadores da variável latente governança apresentam pesos factoriais elevados ($P.F>0.5$) e fiabilidade individuais adequadas ($P.F^2>0.25$) em suporte da validade factorial da variável latente governança. O indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.958$) o que significa que 92% (0.958^2) da variabilidade deste indicador é explicado pela variável latente governança.

Tabela 8.2.9: Estatísticas da análise factorial confirmatória da variável latente Governança - Países com rendimento médio baixo (N=52).

| | Estimate | S.E | C.R | P(> z) | P.Boot | P. F |
|-----|----------|-------|-------|---------|--------|-------|
| va | 1.00 | | | | | 0.695 |
| sta | 1.115 | 0.242 | 4.609 | 0.000 | 0.000 | 0.669 |
| eg | 0.930 | 0.171 | 5.425 | 0.000 | 0.000 | 0.793 |
| qn | 0.593 | 0.173 | 3.439 | 0.001 | 0.001 | 0.495 |
| rl | 1.175 | 0.185 | 6.360 | 0.000 | 0.000 | 0.958 |
| cc | 1.129 | 0.191 | 5.897 | 0.000 | 0.000 | 0.867 |

O modelo factorial confirmatório da variável qualidade de vida, ajustado a uma amostra de 52 países (grupo formado pelos países com rendimento médio baixo) revelou uma qualidade de ajustamento muito boa ($X^2/df=0.58$; $P[X^2>0.2]$; CFI=1.000; TLI=1.000; RMSEA= 0.000; $P[RMSEA<0.05]= 0.867$; SRMR= 0.077) suportando a validade factorial do modelo em causa. A partir da tabela 8.2.10 verifica-se que o indicador relativo ao índice de liberdade económica mundial (EFW, peso factorial = 0.458) apresenta um peso factorial estandardizado inferior ao valor aceitável. Não obstante, os restantes indicadores da variável latente qualidade apresentam pesos factoriais elevados ($P.F> 0.5$) e fiabilidades individuais adequadas ($P.F^2> 0.25$). O indicador relativo á qualidade de saneamento básico (SN) apresenta o maior peso factorial estandardizado ($P.F=0.823$) o que significa que 67% (0.823^2) da variabilidade deste indicador é explicado pela variável latente qualidade. Verifica-se também que todas as trajectórias são positivas (excepto o indicador relativo ao índice de mortalidade infantil - IMR) e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap mas apenas para um nível de significância $\alpha=0.1$. É importante referir que, o indicador relativo á pegada ecológica

apresenta também um peso factorial estandardizado inferior ao valor aceitável (EF, peso factorial = 0.309), e uma vez que o seu coeficiente de trajectória carece de significância estatística (P.boot >0.1) optou-se por retirar este indicador do modelo.

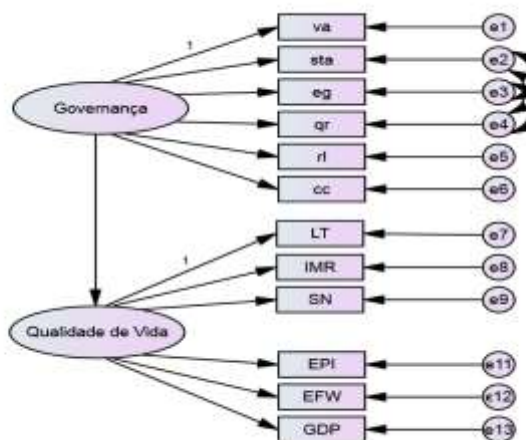
Tabela 8.2.10: Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países com rendimento médio baixo (N=52).

| | Estimate | S.E | C.R | P(> z) | P.Boot | P. F |
|------------|-----------------|------------|------------|-------------------|---------------|-------------|
| <i>LT</i> | 1.000 | | | | | 0.547 |
| <i>IMR</i> | -1.153 | 0.306 | -3.763 | 0.000 | 0.034 | -0.804 |
| <i>SN</i> | 1.378 | 0.364 | 3.788 | 0.000 | 0.005 | 0.823 |
| <i>EF</i> | 0.324 | 0.169 | 1.917 | 0.055 | 0.161 | 0.309 |
| <i>EPI</i> | 0.727 | 0.248 | 2.924 | 0.003 | 0.098 | 0.522 |
| <i>EFW</i> | 0.608 | 0.229 | 2.652 | 0.008 | 0.078 | 0.458 |
| <i>GDP</i> | 0.172 | 0.061 | 2.831 | 0.005 | 0.025 | 0.500 |

Relativamente ao modelo estrutural, (Governança-> Qualidade de Vida) ajustado a uma amostra de 52 países (grupo formado pelos países com rendimento médio baixo), verifica-se que a trajectória entre os factores se revelou positiva e estatisticamente significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$ ($\beta_{\text{Gov-QV}} = 0.430$; SE= 0.181; $p= 0.001$) a par com uma fraca qualidade de ajustamento do modelo ($X^2/\text{df}=2.27$; $P[X^2<0.05]< 0.001$; CFI= 0.791; TLI= 0.740; RMSEA= 0.157; $P[\text{RMSEA}<0.05]< 0.000$; SRMR= 0.115)

Contudo, depois de correlacionados os erros de medida dos indicadores 2, 3, e 4 pertencentes à variável latente governança, foi possível obter uma qualidade de ajustamento significativamente melhor ($X^2/\text{df}=1.68$; $P[X^2<0.05]<0.001$; CFI= 0.894; TLI= 0.860; RMSEA= 0.115; $P[\text{RMSEA}<0.05]< 0.001$; SRMR= 0.105), em suporte da validade estrutural do modelo em causa.

Figura 8.2.5: modelo estrutural CBSEM com 6 resíduos correlacionados (ϵ_2 e ϵ_3 , ϵ_2 e ϵ_4 , ϵ_3 e ϵ_4) e sem o indicador relativo á pegada ecológica (EF) – Países com rendimento médio baixo (N=52).



8.2.6. Modelo de medida e estrutural com método CBSEM - Países com rendimento médio-alto (N=58)

O modelo factorial confirmatório da variável latente governança, ajustado a uma amostra de 58 países (grupo formado pelos países com rendimento médio alto) apresenta índices de qualidade de ajustamento considerados bons ($X^2/df=2.12$; $P[X^2<0.05]$; CFI=0.980; TLI=0.949) e moderados (RMSEA=0.139; $P[RMSEA<0.05]=0.083$; SRMR= 0.031) em suporte da validade factorial do modelo em causa. A partir da tabela 8.2.11, verifica-se que todas as trajetórias são positivas e estatisticamente significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$. O mesmo acontece aquando da aplicação do método de reamostragem bootstrap. Todos os indicadores da variável latente governança apresentam pesos factoriais elevados ($P.F>0.5$) e fiabilidade individuais adequadas ($P.F^2>0.25$) em suporte da validade factorial da variável latente governança. O indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.957$) o que significa que 92% (0.957^2) da variabilidade deste indicador é explicado pela variável latente governança.

Tabela 8.2.11: Estatísticas da análise factorial confirmatória da variável latente Governança - Países com rendimento médio alto (N=58).

| | Estimate | S.E | C.R | P(> z) | P.Boot | P. F |
|-----|-----------------|------------|------------|-------------------|---------------|-------------|
| va | 1.00 | | | | | 0.808 |
| sta | 0.901 | 0.149 | 6.044 | 0.000 | 0.000 | 0.710 |
| eg | 0.879 | 0.117 | 7.527 | 0.000 | 0.000 | 0.833 |
| qn | 0.889 | 0.133 | 6.665 | 0.000 | 0.000 | 0.764 |
| rl | 1.045 | 0.112 | 9.300 | 0.000 | 0.000 | 0.957 |
| cc | 1.019 | 0.116 | 8.814 | 0.000 | 0.000 | 0.923 |

O modelo factorial confirmatório da variável qualidade, ajustado a uma amostra de 58 países (grupo formado pelos países com rendimento médio alto) revelou uma qualidade de ajustamento moderada ($X^2/df=2.12$; $P[X^2<0.05]$; CFI= 0.849; TLI= 0.758) e fraca (RMSEA= 0.140; $P[RMSEA<0.05]= 0.052$; SRMR= 0.078) não suportando a validade factorial do modelo em causa. A partir da tabela 8.2.12 verifica-se que os indicadores relativos á qualidade de saneamento básico (SN, peso factorial = 0.478), ao índice de liberdade económica mundial (EFW, peso factorial = 0.444) e ao produto interno bruto (GDP, peso factorial = 0.208) apresentam pesos factoriais estandardizados inferiores aos valores aceitáveis. Não obstante, os restantes indicadores da variável latente qualidade apresentam pesos factoriais elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$). O indicador índice de mortalidade infantil (IMR) apresenta o maior peso factorial estandardizado ($P.F=0.744$) o que significa que 55% (0.744^2) da variabilidade deste indicador é explicado pela variável latente qualidade. Contudo, verifica-se que todas as trajectórias são positivas (excepto o indicador relativo ao índice de mortalidade infantil - IMR) mas estatisticamente não significativas para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$ (resultados demonstrados pelo valor de probabilidade obtido pelo método bootstrap), levando a concluir que o submodelo de medida pode não ser adequado, pondo em causa o significado do modelo estrutural em estudo.

Tabela 8.2.12: Estatísticas da análise factorial confirmatória da variável latente Qualidade de Vida - Países com rendimento médio alto (N=58).

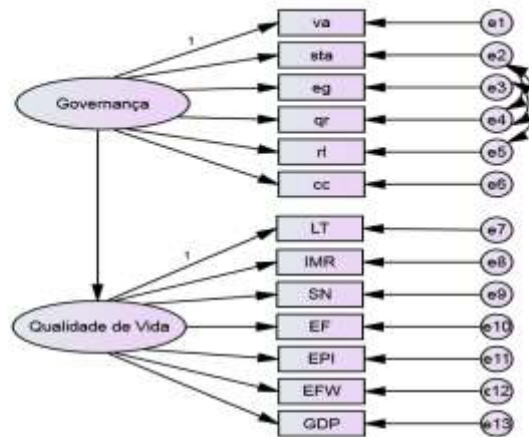
| | Estimate | S.E | C.R | P(> z) | P.Boot | P. F |
|-----|-----------------|------------|------------|-------------------|---------------|-------------|
| LT | 1.000 | | | | | 0.633 |
| IMR | -1.609 | 0.410 | -3.929 | 0.000 | 0.982 | -0.744 |
| SN | 0.758 | 0.259 | 2.927 | 0.003 | 0.760 | 0.478 |
| EF | 0.768 | 0.237 | 3.246 | 0.001 | 0.996 | 0.544 |
| EPI | 1.449 | 0.423 | 3.428 | 0.001 | 0.860 | 0.585 |
| EFW | 1.106 | 0.402 | 2.751 | 0.006 | 0.536 | 0.444 |
| GDP | 0.089 | 0.065 | 1.370 | 0.171 | 0.956 | 0.208 |

Relativamente ao modelo estrutural, (Governança-> Qualidade de Vida) ajustado a uma amostra de 58 países (grupo formado pelos países com rendimento médio alto), verifica-se que a trajectória entre os factores se revelou positiva e estatisticamente significativa para os

níveis de significância $\alpha=0.05$ e $\alpha=0.1$ ($\beta_{\text{Gov-QV}} = 0.243$; SE= 0.083; p= 0.003) a par com uma fraca qualidade de ajustamento do modelo ($X^2/\text{df}=2.66$; $P[X^2<0.05]< 0.001$; CFI= 0.800; TLI= 0.751; RMSEA= 0.169; $P[\text{RMSEA}<0.05]< 0.000$; SRMR= 0.126)

Contudo, depois de correlacionados os erros de medida dos indicadores 2, 3, 4 e 5 pertencentes à variável latente governança, foi possível obter uma qualidade de ajustamento significativamente melhor ($X^2/\text{df}=2.05$; $P[X^2<0.05]<0.001$; CFI= 0.856; TLI= 0.816; RMSEA= 0.135; $P[\text{RMSEA}<0.05]< 0.001$; SRMR= 0.122).

Figura 8.2.6: modelo estrutural CB-SEM com 6 resíduos correlacionados (ϵ_2 e ϵ_3 , ϵ_2 e ϵ_5 , ϵ_3 e ϵ_4) – Países com rendimento médio alto (N=58).



8.3. Eixo C: Avaliação do modelo conceptual com o método baseado na matriz de variâncias – PLS

A estimação do modelo conceptual em estudo através do método PLS foi realizado com recurso ao pacote *plspm* desenvolvido para o *software r* (Sanchez G, 2013). O modelo de medida foi avaliado de acordo com as três medidas de consistência interna (fiabilidade) nomeadamente o α de Cronbach, o rho de dillon Goldstein e os valores do 1º e 2º *eigen values*. A qualidade do modelo estrutural foi avaliada de acordo com o coeficiente de determinação (r^2), do índice de redundância médio (AV.Redund) e do índice de bondade de ajustamento (GOF).

Para verificar os níveis de significância dos parâmetros, assim como a validade do coeficiente estrutural recorreu-se ao método de reamostragem bootstrap (com 1000 subamostras). Consideraram-se significativas, todas as trajectórias com $p.value < 0.1$.

8.3.1. Modelo de Medida e Estrutural com método PLS - Amostra completa (n=215)

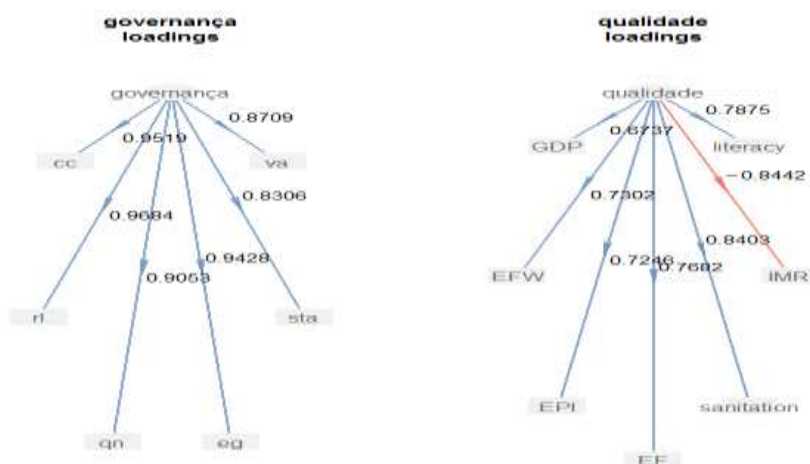
A tabela e figuras seguintes contêm os valores dos índices de ajustamento que caracterizam o modelo de medida em estudo, assim como a natureza dos constructos latentes, o número de indicadores e o valor dos pesos factoriais. A primeira coluna contém o nome da variável latente em estudo, a segunda coluna refere o tipo de medida onde podemos verificar que todas as variáveis em estudo são reflectivas. A terceira coluna mostra o número de indicadores por cada variável latente (6 para a variável governança e 7 para a variável qualidade). A quarta coluna apresenta o valor referente ao alpha de Cronbach, a quinta coluna o valor rho de Dillon-Goldstein e a sexta e sétima colunas o valor do primeiro (eig.1st) e segundo (eig.2nd) *eigen value* para cada bloco respectivamente.

Relativamente aos valores de alpha de Cronbach e de rho de Dillon-Goldstein dos blocos governança e qualidade de vida, verifica-se que ambos apresentam valores superiores a 0.7, o que lhes confere uma boa consistência interna. É possível verificar também que, para ambos os blocos, o valor do primeiro *eigen value* é superior a um, enquanto o valor do segundo *eigen value* é inferior a um validando deste modo, os três índices da verificação de unidimensionalidade dos blocos reflectivos. Todos os indicadores do bloco governança e qualidade apresentam pesos factoriais estandardizados elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$) em suporte da validade factorial do bloco governança e qualidade. O indicador índice de mortalidade infantil (IMR) apresenta o maior peso factorial estandardizado ($P.F=0.844$) do bloco qualidade, o que significa que 71% (0.844^2) da variabilidade deste indicador é explicado pela variável latente qualidade, e o indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.968$) do bloco governança, o que significa que 93% (0.968^2) da variabilidade deste indicador é explicado pelo bloco governança.

Tabela 8.3.1: Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança - amostra total (N=215).

| L.V | Tipo Medida | NºInd | C.alpha | DG.rho | eig.1st | eig.2nd |
|------------|-------------|-------|---------|--------|---------|---------|
| Governança | Reflectiva | 6 | 0.959 | 0.968 | 5.00 | 0.495 |
| Qualidade | Reflectiva | 7 | 0.883 | 0.910 | 4.15 | 0.842 |

Figura 8.3.1: Pesos factoriais estandardizados (loadings) dos indicadores dos blocos governança e qualidade - Amostra total (N=215).



A tabela 8.3.2 apresenta os resultados correspondentes aos índices do modelo estrutural (Governança-> Qualidade de Vida). A primeira coluna contém o nome dos indicadores constituintes dos respectivos blocos, a segunda coluna refere o tipo de bloco, a terceira coluna contém o valor do coeficiente de determinação, a quarta coluna apresenta o valor da comunalidade média (AV.C), a quinta coluna o valor da redundância média (Av.Redun), e finalmente a sexta coluna contém o valor relativo à bondade de ajustamento (GOF).

Relativamente ao modelo estrutural cujos índices estão representados na tabela 8.3.2, verifica-se que, a variável latente governança representa aproximadamente 83% da variabilidade dos seus indicadores e o bloco qualidade representa 59%. O bloco exógeno governança é responsável por 33% da variabilidade dos indicadores do bloco endógeno; o valor relativo ao coeficiente de determinação ($R^2=0.562$) indica que a qualidade de governança explica 56,2% do efeito da qualidade de vida, o que implica um poder de explicação moderado, tal como o valor relativo à bondade de ajustamento (GOF = 0.628).

Tabela 8.3.2: Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – amostra total (N=215).

| V.L | Tipo | R ² | AV.C | Av.Redun | GOF |
|------------|----------|----------------|-------|----------|--------|
| Governança | Exógena | | 0.833 | | |
| Qualidade | Endógena | 0.562 | 0.592 | 0.333 | 0.6289 |

A tabela 8.3.3 apresenta os resultados relativos á validação do coeficiente de trajetória e do coeficiente de determinação do modelo estrutural, obtidos através do procedimento de reamostragem bootstrap. Os resultados são apresentados em nove colunas (as ultimas quatro colunas contém exactamente as mesmas estatísticas mas relativamente ao coeficiente de determinação): o número de réplicas utilizadas no processo de reamostragem, o valor médio do coeficiente de trajetória do modelo estrutural, o erro padrão associado ao valor médio, e finalmente, os valores relativos aos percentis 0.25 (margem inferior) e 0.75 (margem superior) do intervalo de confiança a 95%.

Deste modo, verifica-se que a trajetória entre os factores se revelou positiva e estatisticamente significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$; nenhum dos intervalos de confiança contém o valor zero, o que nos leva a rejeitar H_0 para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$, suportando a validade do coeficiente de trajetória do modelo em causa.

Tabela 8.3.3: Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap - amostra total (N=215).

| <u>N</u> | Coeficiente Estrutural | | | | R ² | | | |
|----------|------------------------|------------|----------------|----------------|----------------|------------|----------------|----------------|
| | <u>Média</u> | <u>E.P</u> | <u>Per.025</u> | <u>Per.975</u> | <u>Média</u> | <u>E.P</u> | <u>Per.025</u> | <u>Per.975</u> |
| 100 | 0.752 | 0.025 | 0.693 | 0.799 | 0.566 | 0.037 | 0.481 | 0.639 |
| 200 | 0.753 | 0.026 | 0.696 | 0.801 | 0.567 | 0.039 | 0.484 | 0.643 |
| 500 | 0.753 | 0.025 | 0.702 | 0.799 | 0.568 | 0.038 | 0.492 | 0.638 |
| 1000 | 0.753 | 0.026 | 0.696 | 0.801 | 0.567 | 0.039 | 0.485 | 0.641 |

8.3.2. Modelo de Medida e Estrutural com método PLS - Países desenvolvidos (n=68)

A tabela 8.3.5 contém os resultados do modelo de medida dos blocos em estudo, obtidos para o grupo formado pelos países cujo rendimento é considerado elevado (desenvolvidos). Neste caso, o tamanho amostral sofre uma redução de 157 observações ficando o grupo reduzido a apenas 68 observações.

Relativamente aos valores de alpha de Cronbach e de rho de Dillon-Goldstein, verifica-se que ambas as variáveis latentes apresentam valores superiores a 0.7, o que significa uma boa

consistência interna para cada bloco. É possível verificar também que, para o bloco governança, o valor do primeiro *eigen value* é superior a 1 e o valor do segundo *eigen value* é inferior a 1 conferindo a validade dos três índices da unidimensionalidade do bloco reflectivo. Não obstante, o valor do segundo *eigen value* do bloco endógeno é superior a 1 contrariando a ideia da unidimensionalidade do bloco.

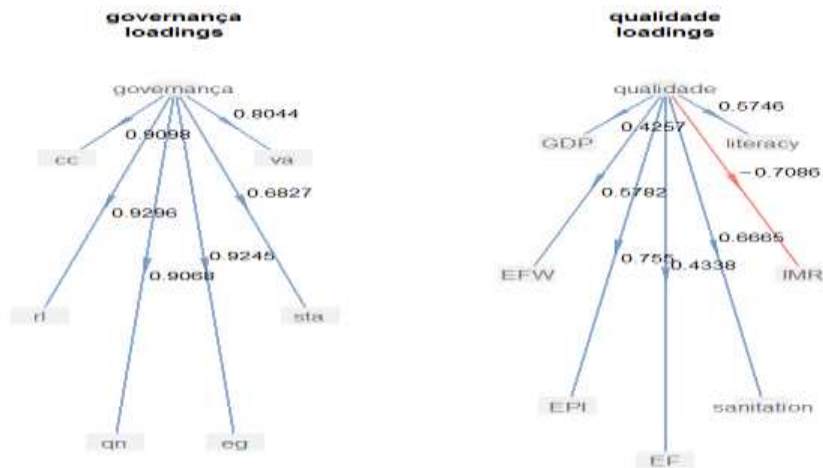
Todos os indicadores do bloco governança apresentam pesos factoriais estandardizados elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$) em suporte da validade factorial do bloco governança e qualidade. O indicador índice de mortalidade infantil (IMR) apresenta o maior peso factorial estandardizado ($P.F=0.844$) do bloco qualidade, o que significa que 71% (0.844^2) da variabilidade deste indicador é explicado pela variável latente qualidade, e o indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.968$) do bloco governança, o que significa que 93% (0.968^2) da variabilidade deste indicador é explicado pela variável latente governança.

Relativamente ao bloco qualidade de vida, verifica-se que os indicadores relativos à pegada ecológica (EF, peso factorial = 0.433) e ao produto interno bruto (EF, peso factorial = 0.433) apresentam pesos factoriais estandardizados inferiores aos valores aceitáveis, no entanto, os indicadores foram mantidos no modelo uma vez que a sua eliminação não contribuiu consideravelmente para a melhoria do mesmo. O indicador índice de percepção ambiental (EPI) apresenta o maior peso factorial estandardizado ($P.F=0.755$) do bloco qualidade, o que significa que 57% (0.755^2) da variabilidade deste indicador é explicado pela variável latente qualidade, e o indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.926$) do bloco governança, o que significa que 85% (0.926^2) da variabilidade deste indicador é explicado pela variável latente governança.

Tabela 8.3.4: Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança – Países desenvolvidos (n=68).

| L.V | Tipo Medida | NºInd | C.alpha | DG.rho | eig.1st | eig.2nd |
|------------|-------------|-------|---------|--------|---------|---------|
| Governança | Reflectiva | 6 | 0.930 | 0.946 | 4.49 | 0.791 |
| Qualidade | Reflectiva | 6 | 0.705 | 0.798 | 2.41 | 1.364 |

Figura 8.3.2: pesos factoriais estandardizados (loadings) dos indicadores dos blocos governança e qualidade – Países desenvolvidos (N=68).



Relativamente ao modelo estrutural, cujos índices estão representados na tabela 8.3.5 verifica-se que o bloco governança representa aproximadamente 75% da variabilidade dos seus indicadores e o bloco qualidade representa 40%. O bloco exógeno governança é responsável por 20% da variabilidade dos indicadores do bloco endógeno; o valor relativo ao coeficiente de determinação ($R^2=0.506$) indica que a qualidade de governança explica 51% do efeito da qualidade de vida, o que implica um poder de explicação moderado, tal como o valor relativo à bondade de ajustamento ($\text{gof} = 0.537$).

Tabela 8.3.5: Estatísticas do modelo estrutural (Governança->Qualidade de Vida) – Países desenvolvidos (N=68).

| V.L | Tipo de medida | R^2 | AV.C | Av.Redun | GOF |
|------------|----------------|-------|-------|----------|-------|
| Governança | Exógena | | 0.747 | | |
| Qualidade | Endógena | 0.506 | 0.398 | 0.201 | 0.537 |

Relativamente á validade do coeficiente estrutural cujos resultados estão apresentados na tabela 8.3.6, verifica-se que a trajectória entre os factores se revelou positiva e estatisticamente significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$; nenhum dos intervalos de confiança contém o valor zero, o que nos leva a rejeitar H_0 para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$, suportando a validade do coeficiente de trajectória do modelo em estudo.

Tabela 8.3.6: Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países desenvolvidos (N=68).

| <i>N</i> | Coeficiente de trajectória | | | | R² | | | |
|----------|-----------------------------------|------------|----------------|----------------|----------------------|------------|----------------|----------------|
| | <i>Média</i> | <i>E.P</i> | <i>Per.025</i> | <i>Per.975</i> | <i>Média</i> | <i>E.P</i> | <i>Per.025</i> | <i>Per.975</i> |
| 100 | 0.713 | 0.068 | 0.569 | 0.823 | 0.514 | 0.096 | 0.324 | 0.678 |
| 200 | 0.723 | 0.062 | 0.599 | 0.830 | 0.527 | 0.088 | 0.359 | 0.689 |
| 500 | 0.721 | 0.064 | 0.584 | 0.840 | 0.524 | 0.092 | 0.341 | 0.706 |
| 1000 | 0.721 | 0.062 | 0.586 | 0.835 | 0.524 | 0.088 | 0.344 | 0.697 |

8.3.3. Modelos de medida e estrutural com método PLS - Países subdesenvolvidos (N=147)

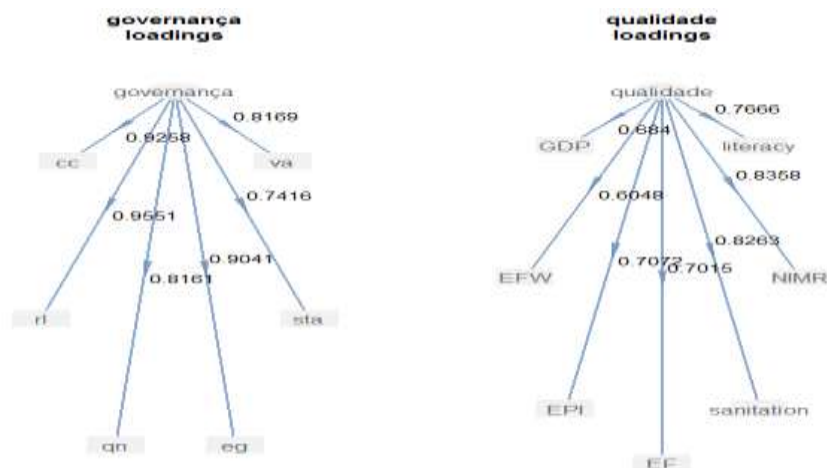
A tabela 8.3.7 contém os resultados do modelo de medida das variáveis latentes em estudo, obtidos para o grupo formado pelos países subdesenvolvidos. Neste caso, o tamanho amostral sofre uma redução de 68 observações ficando o grupo reduzido a 147 observações.

Relativamente aos valores de alpha de Cronbach e de rho de Dillon-Goldstein, verifica-se que ambas as variáveis latentes apresentam valores superiores a 0.7, o que significa uma boa consistência interna para cada bloco. É possível verificar também que, para ambos os blocos, o valor do primeiro *eigenvalue* é superior a um, enquanto o valor do segundo *eigenvalue* é inferior a um validando deste modo, os três índices de verificação da unidimensionalidade dos blocos reflectivos. Todos os indicadores do bloco governança e qualidade apresentam pesos factoriais estandardizados elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$) em suporte da validade factorial do bloco governança e qualidade. O indicador índice de mortalidade infantil (IMR) apresenta o maior peso factorial estandardizado ($P.F=0.835$) do bloco qualidade, o que significa que 69% (0.835^2) da variabilidade deste indicador é explicado pela variável latente qualidade, e o indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.955$) do bloco governança, o que significa que 91% (0.955^2) da variabilidade deste indicador é explicado pela variável latente governança.

Tabela 8.3.7: Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança – Países subdesenvolvidos (N=147).

| L.V | Tipo Medida | NºInd | C.alpha | DG.rho | eig.1st | eig.2nd |
|------------|--------------------|--------------|----------------|---------------|----------------|----------------|
| Governança | Reflectiva | 6 | 0.930 | 0.946 | 4.47 | 0.770 |
| Qualidade | Reflectiva | 7 | 0.856 | 0.892 | 3.82 | 0.817 |

Figura 8.3.3: pesos factoriais estandardizados (loadings) dos indicadores dos blocos governança e qualidade – Países subdesenvolvidos (N=147).



Relativamente ao modelo estrutural, cujos índices estão representados na tabela 8.3.8, verifica-se que, a variável latente governança representa aproximadamente 74% da variabilidade dos seus indicadores e o bloco qualidade representa 54%. O bloco exógeno governança é responsável por 19% da variabilidade dos indicadores do bloco endógeno; o valor relativo ao coeficiente de determinação ($R^2=0.343$) indica que a qualidade de governança explica 34% do efeito da qualidade de vida, o que implica um poder de explicação moderado, tal como o valor relativo à bondade de ajustamento ($\text{gof} = 0.467$).

Tabela 8.3.8: Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países subdesenvolvidos (N=147)

| V.L | Tipo de medida | R^2 | AV.C | Av.Redun | GOF |
|------------|----------------|-------|-------|----------|-------|
| Governança | Exógena | | 0.745 | | |
| Qualidade | Endógena | 0.343 | 0.542 | 0.186 | 0.467 |

Relativamente á validade do coeficiente estrutural cujos resultados estão apresentados na tabela 8.3.9, verifica-se que, a trajetória entre os factores se revelou positiva e estatisticamente significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$; nenhum dos intervalos de confiança contém o valor zero, o que nos leva a rejeitar H_0 para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$, suportando a validade do coeficiente de trajetória do modelo em estudo.

Tabela 8.3.9: Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países subdesenvolvidos (N=147).

| <i>N</i> | Coeficiente de trajectória | | | | R² | | | |
|----------|-----------------------------------|------------|----------------|----------------|----------------------|------------|----------------|----------------|
| | <i>Média</i> | <i>E.P</i> | <i>Per.025</i> | <i>Per.975</i> | <i>Média</i> | <i>E.P</i> | <i>Per.025</i> | <i>Per.975</i> |
| 100 | 0.594 | 0.044 | 0.501 | 0.665 | 0.355 | 0.052 | 0.251 | 0.443 |
| 200 | 0.590 | 0.050 | 0.495 | 0.682 | 0.350 | 0.058 | 0.245 | 0.465 |
| 500 | 0.592 | 0.049 | 0.491 | 0.678 | 0.353 | 0.057 | 0.241 | 0.459 |
| 1000 | 0.594 | 0.045 | 0.503 | 0.678 | 0.355 | 0.054 | 0.253 | 0.459 |

8.3.4. *Análise dos modelos de medida e estrutural com método PLS - Países com rendimento baixo (n=38)*

A tabela 8.3.10 contém os resultados do modelo de medida das variáveis latentes em estudo, obtidos para o grupo formado pelos países com vencimento baixo. Neste caso, o tamanho amostral sofre uma redução de 177 observações ficando o grupo reduzido a apenas 38 observações.

Relativamente aos valores de alpha de Cronbach e de rho de Dillon-Goldstein, verifica-se que ambas as variáveis latentes apresentam valores superiores a 0.7, o que significa uma boa consistência interna para cada bloco. É possível verificar também que, para ambos os blocos, o valor do primeiro *eigenvalue* é superior a um, enquanto o valor do segundo *eigenvalue* é inferior a um validando deste modo, os três índices de verificação da unidimensionalidade dos blocos reflectivos.

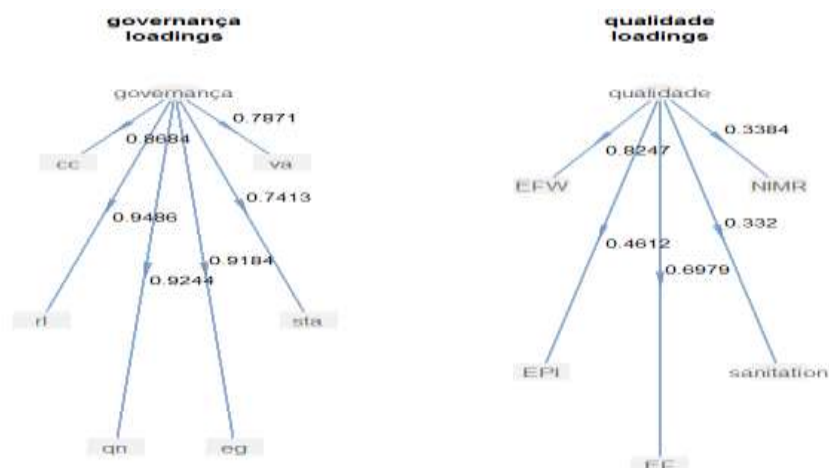
Todos os indicadores do bloco governança apresentam pesos factoriais estandardizados elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$) em suporte da validade factorial do bloco governança e qualidade. O indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.948$) do bloco governança, o que significa que 89% (0.955^2) da variabilidade deste indicador é explicado pela variável latente governança. Relativamente ao bloco qualidade, verifica-se que os indicadores relativos ao índice de mortalidade infantil (NIMR, peso factorial = 0.338) á qualidade de saneamento básico (SN, peso factorial = 0.332) e ao índice de percepção ambiental (EPI, peso factorial = 0.461) apresentam pesos factoriais estandardizados inferiores aos valores aceitáveis, no entanto, os indicadores foram mantidos no modelo uma vez que a sua eliminação não contribuiu consideravelmente para a melhoria do mesmo. O indicador la liberdade económica mundial (EFW) apresenta o maior peso factorial estandardizado ($P.F=0.824$) do bloco qualidade, o que

significa que 67% (0.755^2) da variabilidade deste indicador é explicado pelo bloco qualidade. É importante referir que, os indicadores relativos à qualidade de literacia (LT, peso factorial = 0.058) e ao produto interno bruto (GDP, peso factorial = 0.243) apresentaram pesos factoriais estandardizados inferiores aos valores aceitáveis. Deste modo, uma vez que a sua eliminação contribui consideravelmente para a melhoria da consistência interna e verificação da unidimensionalidade do bloco qualidade (o valor de alfa de Cronbach do bloco subiu de 0.613 para 0.703 e o segundo *eigenvalue* baixou de 1.07 para 0.970) optou-se por retirar estes indicadores do bloco.

Tabela 8.3.10: Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança – Países com rendimento baixo (N=38).

| L.V | Tipo Medida | NºInd | C.alpha | DG.rho | eig.1st | eig.2nd |
|------------|-------------|-------|---------|--------|---------|---------|
| Governança | Reflectiva | 6 | 0.933 | 0.948 | 4.53 | 0.524 |
| Qualidade | Reflectiva | 5 | 0.703 | 0.809 | 2.31 | 0.970 |

Figura 8.3.4: pesos factoriais estandardizados (loadings) dos indicadores dos blocos governança e qualidade – Países com rendimento baixo (N=38).



Relativamente ao modelo estrutural, cujos índices estão representados na tabela 8.3.11, verifica-se que, a variável latente governança representa aproximadamente 75% da variabilidade dos seus indicadores e o bloco qualidade representa 32%. O bloco exógeno governança é responsável por apenas 6% da variabilidade dos indicadores do bloco endógeno; o valor relativo ao coeficiente de determinação ($R^2=0.183$) indica que a qualidade de governança explica 18% do efeito da qualidade de vida, o que implica um poder de explicação fraco, tal como o valor relativo à bondade de ajustamento ($\text{gof} = 0.319$).

Tabela 8.3.11: Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países com rendimento baixo (n=38)

| V.L | Tipo de medida | R ² | AV.C | Av.Redun | GOF |
|------------|----------------|----------------|-------|----------|-------|
| Governança | Exógena | | 0.754 | | |
| Qualidade | Endógena | 0.183 | 0.321 | 0.058 | 0.319 |

Relativamente á validade do coeficiente estrutural cujos resultados estão apresentados na tabela, verifica-se que, a trajectória entre os factores se revelou positiva mas estatisticamente não significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$; todos os intervalos de confiança contém o valor zero, o que nos leva a rejeitar H_0 para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$, não suportando a validade do coeficiente de trajectória do modelo em estudo.

Tabela 8.3.12: Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países com rendimento baixo (N=52).

| <u>N</u> | Coeficiente Estrutural | | | | R² | | | |
|----------|-------------------------------|------------|----------------|----------------|----------------------|------------|----------------|----------------|
| | <u>Média</u> | <u>E.P</u> | <u>Per.025</u> | <u>Per.975</u> | <u>Média</u> | <u>E.P</u> | <u>Per.025</u> | <u>Per.975</u> |
| 100 | 0.154 | 0.504 | -0.646 | 0.653 | 0.275 | 0.105 | 0.094 | 0.517 |
| 200 | 0.049 | 0.533 | -0.682 | 0.646 | 0.285 | 0.097 | 0.128 | 0.475 |
| 500 | 0.085 | 0.534 | -0.666 | 0.660 | 0.292 | 0.091 | 0.126 | 0.497 |
| 1000 | 0.069 | 0.526 | -0.665 | 0.648 | 0.281 | 0.092 | 0.116 | 0.468 |

8.3.5. Modelo de medida e estrutural com método PLS - países com rendimento médio-baixo (N=52)

A tabela 8.3.13 contém os resultados do modelo de medida das variáveis latentes em estudo, obtidos para o grupo formado pelos países com vencimento médio-baixo. Neste caso, o tamanho amostral sofre uma redução de 163 observações ficando o grupo reduzido a apenas 52 observações.

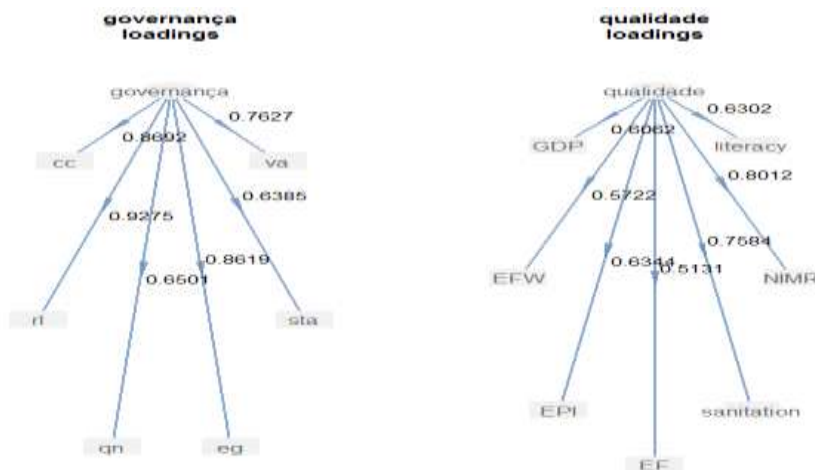
Relativamente aos valores de alpha de Cronbach e de rho de Dillon-Goldstein, verifica-se que, ambos os blocos apresentam valores superiores a 0.7, o que significa uma boa consistência interna para cada bloco. É possível verificar também que, para ambos os blocos, o valor do primeiro e segundo *eigenvalue* é superior a um, contrariando, deste modo, a ideia de unidimensionalidade dos blocos reflectivos. Todos os indicadores do bloco governança e qualidade apresentam pesos factoriais estandardizados elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$) em suporte da validade factorial do bloco governança e qualidade. O indicador índice de mortalidade infantil (IMR) apresenta o maior peso factorial estandardizado ($P.F=0.801$) do bloco qualidade, o que significa que 64% (0.801^2) da variabilidade deste indicador é explicado pela variável latente qualidade, e o indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.927$) do bloco

governança, o que significa que 85% (0.927^2) da variabilidade deste indicador é explicado pela variável latente governança.

Tabela 8.3.13: Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança – Países com rendimento médio baixo (N=52).

| L.V | Tipo Medida | NºInd | C.alpha | DG.rho | eig.1st | eig.2nd |
|------------|-------------|-------|---------|--------|---------|---------|
| Governança | Reflectiva | 6 | 0.878 | 0.910 | 3.80 | 1.15 |
| Qualidade | Reflectiva | 7 | 0.768 | 0.835 | 3.01 | 1.02 |

Figura 8.3.5: Pesos factoriais estandardizados (loadings) dos indicadores dos blocos governança e qualidade – Países com rendimento médio baixo (N=52).



Relativamente ao modelo estrutural, cujos índices estão representados na tabela 8.3.14, verifica-se que, a variável latente governança representa aproximadamente 63% da variabilidade dos seus indicadores e o bloco qualidade representa 43%. O bloco exógeno governança é responsável por 13% da variabilidade dos indicadores do bloco endógeno; o valor relativo ao coeficiente de determinação ($R^2=0.298$) indica que a qualidade de governança explica 30% do efeito da qualidade de vida, o que implica um poder de explicação moderado, tal como o valor relativo à bondade de ajustamento ($\text{gof} = 0.393$).

Tabela 8.3.14: Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países com rendimento médio baixo (N=52)

| V.L | Tipo | R^2 | AV.C | Av.Redun | GOF |
|------------|----------|-------|-------|----------|-------|
| Governança | Exógena | | 0.628 | | |
| Qualidade | Endógena | 0.298 | 0.425 | 0.127 | 0.393 |

Relativamente á validade do coeficiente estrutural cujos resultados estão apresentados na tabela 8.3.15, verifica-se que, a trajectória entre os factores se revelou positiva e estatisticamente significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$; nenhum dos intervalos de confiança contém o valor zero, o que nos leva a rejeitar H_0 para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$, suportando a validade do coeficiente de trajectória do modelo em estudo.

Tabela 8.3.15: Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países com rendimento médio baixo (N=52).

| <i>N</i> | Coeficiente Estrutural | | | | R² | | | |
|----------|-------------------------------|------------|----------------|----------------|----------------------|------------|----------------|----------------|
| | <i>Média</i> | <i>E.P</i> | <i>Per.025</i> | <i>Per.975</i> | <i>Média</i> | <i>E.P</i> | <i>Per.025</i> | <i>Per.975</i> |
| 100 | 0.584 | 0.072 | 0.454 | 0.712 | 0.346 | 0.084 | 0.206 | 0.508 |
| 200 | 0.598 | 0.072 | 0.456 | 0.737 | 0.363 | 0.085 | 0.208 | 0.543 |
| 500 | 0.588 | 0.073 | 0.445 | 0.725 | 0.351 | 0.086 | 0.198 | 0.525 |
| 1000 | 0.587 | 0.088 | 0.430 | 0.737 | 0.352 | 0.092 | 0.186 | 0.544 |

8.3.6. Modelo de medida e estrutural com método PLS - Países com rendimento médio-alto (N=58)

A tabela 8.3.16 contém os resultados do modelo de medida das variáveis latentes em estudo, obtidos para o grupo formado pelos países com vencimento médio-baixo. Neste caso, o tamanho amostral sofre uma redução de 157 observações ficando o grupo reduzido a apenas 58 observações.

Relativamente aos valores de alpha de Cronbach e de rho de Dillon-Goldstein, verifica-se que ambas as variáveis latentes apresentam valores superiores a 0.7, o que significa uma boa consistência interna para cada bloco. É possível verificar também que, para ambos os blocos, o valor do primeiro *eigenvalue* é superior a um, enquanto o valor do segundo *eigenvalue* é inferior a um validando deste modo, os três índices da verificação de unidimensionalidade dos blocos reflectivos.

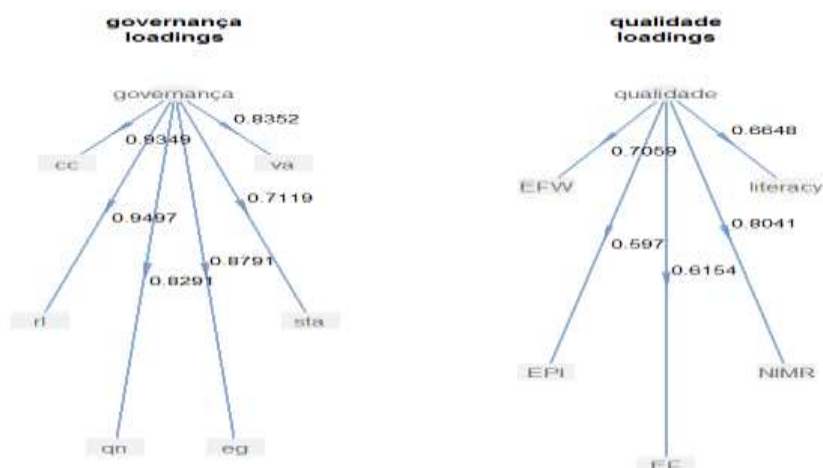
Todos os indicadores do bloco governança e qualidade apresentam pesos factoriais estandardizados elevados ($P.F > 0.5$) e fiabilidades individuais adequadas ($P.F^2 > 0.25$) em suporte da validade factorial do bloco governança e qualidade. O indicador índice de mortalidade infantil (IMR) apresenta o maior peso factorial estandardizado ($P.F=0.797$) do bloco qualidade, o que significa que 63% (0.797^2) da variabilidade deste indicador é explicado pela variável latente qualidade, e o indicador estado de direito (rl) apresenta o maior peso factorial estandardizado ($P.F=0.950$) do bloco governança, o que significa que 90% (0.950^2) da variabilidade deste indicador é explicado pela variável latente governança. É importante referir que, os indicadores relativos à qualidade de saneamento básico (SN, peso factorial = 0.2743) e

ao produto interno bruto (GDP, peso factorial = 0.423) apresentaram pesos factoriais estandardizados inferiores aos valores aceitáveis. Deste modo, uma vez que a sua eliminação contribui consideravelmente para a melhoria da consistência interna e verificação da unidimensionalidade do bloco qualidade (o valor de alfa de Cronbach do bloco subiu de 0.613 para 0.719 e o segundo *eigenvalue* baixou de 1.12 para 0.90) optou-se por retirar estes indicadores do bloco.

Tabela 8.3.16: Estatísticas do modelo de medida para os blocos Qualidade de Vida e Governança – Países com rendimento médio alto (N=58).

| L.V | Tipo Medida | NºInd | C.alpha | DG.rho | eig.1st | eig.2nd |
|------------|-------------|-------|---------|--------|---------|---------|
| Governança | Reflectiva | 6 | 0.928 | 0.944 | 4.44 | 0.830 |
| Qualidade | Reflectiva | 5 | 0.719 | 0.818 | 2.38 | 0.970 |

Figura 8.3.6: Pesos factoriais estandardizados (loadings) dos indicadores dos blocos governança e qualidade – Países com rendimento médio alto (N=58).



Relativamente ao modelo estrutural, cujos índices estão representados na tabela 8.3.17 verifica-se que a variável latente governança representa aproximadamente 74% da variabilidade dos seus indicadores e o bloco qualidade representa 47%. O bloco exógeno governança é responsável por 13% da variabilidade dos indicadores do bloco endógeno; o valor relativo ao coeficiente de determinação ($R^2=0.285$) indica que a qualidade de governança explica 30% do efeito da qualidade de vida, o que implica um poder de explicação moderado, tal como o valor relativo à bondade de ajustamento ($\text{gof} = 0.414$).

Tabela 8.3.17: Estatísticas do modelo estrutural (Governança-> Qualidade de Vida) – Países com rendimento médio alto (N=58)

| V.L | Tipo | R^2 | AV.C | Av.Redun | GOF |
|------------|----------|-------|-------|----------|-------|
| Governança | Exógena | | 0.740 | | |
| Qualidade | Endógena | 0.285 | 0.465 | 0.133 | 0.414 |

Relativamente á validade do coeficiente estrutural cujos resultados estão apresentados na tabela 8.3.18, verifica-se que, a trajectória entre os factores se revelou positiva e estatisticamente significativa para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$; nenhum dos intervalos de confiança contém o valor zero, o que nos leva a rejeitar H_0 para os níveis de significância $\alpha=0.05$ e $\alpha=0.1$, suportando a validade do coeficiente de trajectória do modelo em estudo.

Tabela 8.3.18: Validação do coeficiente estrutural (Governança-> Qualidade de Vida) e coeficiente de determinação através do método bootstrap – Países com rendimento médio alto (N=58).

| <i>N</i> | Coeficiente Estrutural | | | | R² | | | |
|----------|-------------------------------|------------|----------------|----------------|----------------------|------------|----------------|----------------|
| | <i>Média</i> | <i>E.P</i> | <i>Per.025</i> | <i>Per.975</i> | <i>Média</i> | <i>E.P</i> | <i>Per.025</i> | <i>Per.975</i> |
| 100 | 0.573 | 0.068 | 0.455 | 0.726 | 0.333 | 0.081 | 0.207 | 0.527 |
| 200 | 0.562 | 0.067 | 0.436 | 0.680 | 0.321 | 0.074 | 0.190 | 0.462 |
| 500 | 0.566 | 0.071 | 0.425 | 0.707 | 0.325 | 0.081 | 0.180 | 0.500 |
| 1000 | 0.563 | 0.071 | 0.417 | 0.697 | 0.322 | 0.080 | 0.174 | 0.487 |

8.4. Eixo D: Comparação dos coeficientes estruturais entre os diferentes subgrupos

No que concerne à estimação do modelo estrutural em estudo através do método CBSEM, a tabela 8.4.1 apresenta os valores dos coeficientes estruturais (para os seis grupos de países) estimados com (β_{boot}) e sem (β) recurso ao método bootstrap, o valor dos erros padrão ($E.P_{boot}$) e os valores de probabilidade (p.value) associados aos respectivos coeficientes estruturais estimados com o método bootstrap. No que diz respeito à estimação do modelo estrutural com o método PLS, a tabela x apresenta igualmente os valores referentes aos coeficientes estruturais (para os seis grupos de países), estimados com e sem recurso ao método bootstrap; os valores dos erros padrão, e os valores correspondentes aos percentis 0.25 e 0.75 dos intervalos de confiança a 95% para os coeficientes estruturais, calculados através do método bootstrap.

Tabela 8.4.1: Análise e comparação dos coeficientes estruturais (Governança-> Qualidade de Vida) com o método CBSEM e PLS

| | <u>CBSEM</u> | | | | <u>PLS</u> | | | | |
|-----------------|--------------|----------------|--------------|---------|------------|----------------|--------------|------------|------------|
| | β | β_{boot} | $E.P_{boot}$ | P.value | β | β_{boot} | $E.P_{boot}$ | $P_{0.25}$ | $P_{0.75}$ |
| A. Total | 0.722 | 0.720 | 0.069 | 0.000 | 0.749 | 0.753 | 0.026 | 0.696 | 0.801 |
| PD | 0.160 | 0.160 | 0.062 | 0.004 | 0.701 | 0.721 | 0.061 | 0.586 | 0.835 |
| PVD | 0.708 | 0.708 | 0.110 | 0.000 | 0.605 | 0.594 | 0.049 | 0.503 | 0.678 |
| PRB | 0.102 | -0.116 | 0.634 | 0.794 | 0.069 | 0.462 | 0.525 | -0.665 | 0.648 |
| PRMB | 0.483 | 0.484 | 0.190 | 0.001 | 0.546 | 0.566 | 0.075 | 0.430 | 0.737 |
| PRMA | 0.243 | 0.243 | 0.127 | 0.003 | 0.586 | 0.588 | 0.073 | 0.417 | 0.697 |

A análise de trajetórias entre os factores com o método CBSEM revelou que a trajetória 'Gov-QV' da amostra total é a que apresenta maior peso ($\beta_{Gov.QV}=0.772$; $\beta_{boot;Gov.QV}=0.720$; $SE=0.069$; $p.value=0.000$), seguida pela trajetória 'Gov-QV' dos países subdesenvolvidos ($\beta_{Gov.QV}=0.708$; $\beta_{boot;Gov.QV}=0.708$; $SE=0.110$; $p.value=0.000$), países com rendimento médio-baixo ($\beta_{Gov.QV}=0.483$; $\beta_{boot;Gov.QV}=0.484$; $SE=0.190$; $p.value=0.001$), países com rendimento médio-alto ($\beta_{Gov.QV}=0.243$; $\beta_{boot;Gov.QV}=0.243$; $SE=0.127$; $p.value=0.003$), e dos países desenvolvidos ($\beta_{Gov.QV}=0.160$; $\beta_{boot;Gov.QV}=0.160$; $SE=0.062$; $p.value=0.004$). Finalmente, a trajetória relativa aos países com rendimento baixo revelou-se não significativa ($\beta_{Gov.QV}=0.102$; $\beta_{boot;Gov.QV}=-0.116$; $SE=0.634$; $p.value=0.794$).

A análise de trajetórias entre os factores com o método PLS revelou que a trajetória 'Gov-QV' da amostra total é a que apresenta maior peso ($\beta_{Gov.QV}=0.794$; $\beta_{boot;Gov.QV}=0.753$; $SE=0.026$; IC 95% [0.696; 0.801]), seguida pela trajetória 'Gov-QV' dos países desenvolvidos ($\beta_{Gov.QV}=0.701$; $\beta_{boot;Gov.QV}=0.721$; $SE=0.061$; IC 95% [0.586; 0.835]), países subdesenvolvidos ($\beta_{Gov.QV}=0.605$; $\beta_{boot;Gov.QV}=0.594$; $SE=0.049$; IC 95% [0.503; 0.678]), países com rendimento médio-alto ($\beta_{Gov.QV}=0.586$; $\beta_{boot;Gov.QV}=0.588$; $SE=0.073$; IC 95% [0.417; 0.697]), e dos países com

rendimento médio-baixo ($\beta_{\text{Gov.QV}}=0.546$; $\beta_{\text{boot;Gov.QV}}=0.566$; $\text{SE}=0.062$; IC 95% [0.430; 0.737]). Finalmente, a trajectória relativa aos países com rendimento baixo revelou-se não significativa ($\beta_{\text{Gov.QV}}=0.069$; $\beta_{\text{boot;Gov.QV}}=0.462$; $\text{SE}=0.525$; IC 95% [-0.665; 0.648]).

Relativamente à análise multigrupos, o modelo estrutural ‘Gov-QV’ foi analisado e comparado entre os países desenvolvidos vs países subdesenvolvidos; países com rendimento baixo vs. grupo formado pelos restantes países (de molde a facilitar a análise, todos os países não pertencentes aos países com rendimento baixo foram inseridos num só grupo. O mesmo aconteceu para as outras comparações.); países com rendimento médio-baixo vs. grupo formado pelos restantes países; e países com rendimento médio-alto vs. grupo formado pelos restantes países.

No que concerne à estimação realizada pelo método CBSEM, a invariância¹ do modelo estrutural nos respectivos subgrupos foi avaliada por comparação do modelo com coeficientes estruturais livres vs. o modelo com coeficientes estruturais fixos e iguais nos dois grupos. A significância estatística da diferença dos dois modelos foi feita com o teste Qui-quadrado da diferença de modelos aninhados (colunas 2,3 e 4 da tabela 8.4.2), verificando-se que todos os grupos comparados diferem significativamente para um valor de $q < 0.05$.

No que concerne à estimação realizada pelo método PLS, a invariância do modelo estrutural nos respectivos subgrupos foi avaliada através do teste das permutas, uma vez que este é um teste de distribuição livre. As colunas 5 e 6 da tabela 8.4.2 exibem os valores das diferenças absolutas (Dif.Abs) dos coeficientes estruturais entre os dois grupos comparados, e os valores de probabilidade (p.value) respectivamente. Como se pode verificar, também neste caso, todos os coeficientes estruturais diferem significativamente entre os grupos.

Tabela 8.4.2: Estatísticas resultantes da análise multigrupos com os métodos CBSEM e PLS.

| | <u>CBSEM</u> | | | <u>PLS</u> | |
|-------------------|--------------|---------|---------|------------|---------|
| | Chisq dif. | Gl dif. | p.value | Dif.Abs | p.value |
| PD vs. PVD | 192.87 | 23 | 0.000 | 0.115 | 0.029 |
| PRB vs O | 82.761 | 23 | 0.001 | 0.275 | 0.029 |
| PRMB vs.O | 95.605 | 23 | 0.002 | 0.205 | 0.009 |
| PRMA vs. O | 168.41 | 23 | 0.000 | 0.193 | 0.009 |

¹No contexto da física, a invariância é o nome dado à propriedade de uma grandeza que não se modifica quando ocorre uma mudança nas condições do observador. As variáveis com esta propriedade designam-se variáveis invariantes. Este conceito pode estender-se, de forma genérica, também para o campo da análise de modelos de equações estruturais em ciências sociais e humanas.

8.5. *Eixo E Comparação das propriedades dos estimadores utilizados nos métodos CBSEM (ML) e PLS, assentes no processo de reamostragem bootstrap através de uma simulação de Monte Carlo*

No que concerne à comparação das propriedades dos estimadores utilizados nos métodos CBSEM (ML) e VBSEM (PLS), assentes no processo de reamostragem bootstrap, foi conduzida uma simulação de Monte Carlo no âmbito de avaliar o comportamento dos parâmetros em termos de precisão (viés) e eficiência (erros padrão-E.P) para cada subgrupo constituído. A simulação de Monte Carlo para o método CBSEM (ML) foi realizada com recurso ao pacote *simsem* desenvolvido para o software r (versão 0.5; Schoemenn, 2013). A simulação de Monte Carlo para o método VBSEM (PLS) foi realizada com recurso ao pacote *matrixpls* desenvolvido para o software r (versão 0.5; Schoemenn, 2013). Para detectar se existem diferenças significativas ao nível dos estimadores foi conduzido um teste de Friedman para medidas repetidas, cujos resultados são exibidos na tabela 8.5.

Tabela 8.5: viés médio e erros padrão do modelo de medida e estrutural para cada tamanho amostral (n) e método de estimação (ML e PLS).

| Subgrupo | n | Método | Modelo de medida | | Modelo estrutural | |
|----------|-----|-----------|------------------|--------------|-------------------|--------------|
| | | | Viés | E.P | Viés | E.P |
| PRB | 38 | ML | 0.030 | 0.205 | 0.015 | 0.200 |
| | | PLS | 0.122 | 0.497 | 0.039 | 0.389 |
| PRMB | 52 | ML | -0.013 | 0.169 | 0.009 | 0.187 |
| | | PLS | 0.101 | 0.296 | -0.052 | 0.157 |
| PRMA | 58 | ML | -0.019 | 0.165 | 0.002 | 0.158 |
| | | PLS | -0.045 | 0.470 | 0.039 | 0.241 |
| PD | 68 | ML | -0.028 | 0.235 | 0.007 | 0.131 |
| | | PLS | -0.043 | 0.535 | 0.037 | 0.185 |
| PVD | 147 | ML | -0.008 | 0.101 | 0.014 | 0.129 |
| | | PLS | 0.179 | 0.110 | -0.199 | 0.055 |
| A.Total | 215 | ML | -0.005 | 0.084 | 0.008 | 0.102 |
| | | PLS | 0.180 | 0.094 | -0.199 | 0.049 |

Deste modo, a partir da tabela 8.5, verifica-se que para $\alpha=0.05$ o viés médio ($F(1)=6$; $p.value=0.014$) e as estimativas dos erros padrão ($F(1)=6$; $p.value=0.001$) dos modelos de medida diferem significativamente, evidenciando que o viés médio e os respectivos erros padrão obtidos através do método PLS assente no processo de reamostragem bootstrap são superiores ao viés médio e erros padrão obtidos através do método CBSEM (ML) assente no processo de reamostragem bootstrap Bollen-Stine.

Relativamente ao modelo estrutural, verifica-se que para $\alpha=0.05$ o viés médio ($F(1)=6$; $p.value=0.018$) e as estimativas dos erros padrão ($F(1)=6$; $p.value=0.014$) dos modelos de medida também diferem significativamente, não obstante verifica-se que, apesar do viés médio obtido através do método PLS assente no processo de reamostragem bootstrap se

mostrar mais elevado em todos os subgrupos, o mesmo não acontece com as estimativas dos erros padrão para amostras de maior dimensão ($n=147$ e $n=215$), onde neste caso os valores dos erros padrão obtidos através do método CBSEM (ML) assente no processo de reamostragem bootstrap Bollen-Stine são claramente mais elevados do que aqueles obtidos através do método PLS.

9. Discussão de Resultados

No nono capítulo desta tese procura dar-se sentido aos resultados obtidos na secção anterior, abordando os resultados mais pertinentes provenientes da aplicação dos métodos CBSEM e PLS ao modelo conceptual Gov-QV nos seis grupos de países.

Avaliação do modelo estrutural

Relativamente aos coeficientes estruturais originais do modelo conceptual em estudo, obtidos para os seis grupos de países através do método CBSEM, verifica-se que, para todas as amostras, a qualidade de governança tem efeito positivo e significativo na qualidade de vida, excepto na amostra referente aos países com rendimento baixo ($\beta_{\text{Gov-QV}}=0.122$; $p.\text{value}>0.1$). É importante realçar que o efeito que qualidade da governança tem sobre a qualidade de vida é maior nas amostras de maior dimensão ($n=215$ e $n=147$). Relativamente aos coeficientes estruturais do modelo conceptual em estudo obtidos para os seis grupos de países através do método CBSEM assente no processo de reamostragem bootstrap, verifica-se que são quase idênticos aos coeficientes originais à excepção do coeficiente estrutural relativo aos países com rendimento baixo, contrariando a hipótese inicial, uma vez que constata que a qualidade de governação tem um impacto negativo na qualidade de vida das populações. No entanto, também este coeficiente carece de significância estatística ($\beta_{\text{boot;Gov-QV}}=-0.116$,; $p.\text{value}>0.1$).

Relativamente aos coeficientes estruturais originais do modelo conceptual em estudo, obtidos para os seis grupos de países através do método PLS, verifica-se que, para todas as amostras, a qualidade da governança tem um efeito positivo e significativo na variável latente qualidade de vida, excepto na amostra referente aos países com rendimento baixo ($\beta_{\text{Gov-QV}}=0.069$; $p.\text{value}>0.1$). Relativamente aos coeficientes estruturais do modelo conceptual em estudo obtidos para os seis grupos de países através do método PLS assente no processo de reamostragem bootstrap, verifica-se que são quase idênticos aos coeficientes originais à excepção do coeficiente estrutural relativo aos países com rendimento baixo onde o efeito passa a ser bastante superior aquando da aplicação do método de reamostragem bootstrap ($\beta_{\text{boot;Gov-QV}}=0.462$,; $p.\text{value}>0.1$). Não obstante, também neste caso este coeficiente carece de significância estatística.

Avaliação do modelo de medida

No que concerne à análise da variável latente governança, verificou-se que, para os seis grupos de países, o modelo factorial confirmatório estimado com o método CBSEM apresentou, no geral, uma qualidade de ajustamento boa e moderada. No que diz respeito aos pesos factoriais estandardizados verifica-se que o indicador estado de direito (rl) se destaca por ter sido a mais explicativa na operacionalização do constructo latente governança. Com efeito, este indicador apresenta um peso factorial superior ao dos outros indicadores em todos os subgrupos,

vincando a importância e a dimensão que o estado de direito representa na qualidade de governação das nações. A única excepção diz respeito aos países desenvolvidos cujo indicador com maior peso factorial estandardizado é o indicador correspondente à eficácia governamental (eg), e que marca a importância quer da redistribuição dos bens públicos quer da produção de novas políticas, como factores essenciais para a qualidade de governação desses países.

No que concerne à análise da variável latente qualidade de vida, verificou-se que, o modelo factorial confirmatório estimado com o método CBSEM apresentou uma qualidade de ajustamento muito boa para a amostra total, para o subgrupo formado pelos países subdesenvolvidos e para o subgrupo formado pelos países com rendimento médio baixo. Não obstante, a qualidade de ajustamento revelou-se moderada/fraca para os subgrupos formados pelos países desenvolvidos, países com rendimento baixo e países com rendimento médio alto. No que diz respeito aos pesos factoriais estandardizados, verifica-se que, no geral (amostra total, países subdesenvolvidos, países desenvolvidos, países com rendimento baixo e países com rendimento médio baixo) o indicador correspondente à facilidade de acesso ao saneamento básico (SN) tem um peso factorial estandardizado superior ao dos outros indicadores, vincando a importância e dimensão que a facilidade de acesso ao saneamento básico representa na qualidade de vida destes países. As duas excepções são constituídas pelos países desenvolvidos e países com rendimento médio alto. Nos primeiros, o indicador com maior peso factorial corresponde ao índice de percepção ambiental (EPI), o que significa que uma melhor qualidade de vida se traduz pela sensibilidade que cada nação tem relativamente aos pressupostos ambientais assumidos no índice de percepção ambiental. A segunda excepção é referente aos países com rendimento médio alto, onde o indicador com maior peso factorial corresponde ao índice de mortalidade infantil (IMR), vincando a importância e dimensão que o sistema de saúde e políticas de saúde pública representam na qualidade de vida das populações.

Relativamente à análise da variável latente governança e qualidade de vida, realizada através do método PLS, verificou-se que os blocos formados pelos seis grupos de países apresentaram uma boa consistência interna. Os pesos factoriais estandardizados do modelo de medida da variável latente governança, estimados pelo método PLS, mostram que o indicador estado de direito tem um peso factorial estandardizado superior ao dos outros indicadores em todas as amostras, vincando do mesmo modo, a importância e dimensão que o estado de direito (rl) representa na qualidade de governação das nações.

Os pesos factoriais do modelo de medida da variável latente qualidade, estimados pelo método PLS, mostram que, no geral (amostra total, países subdesenvolvidos, países com rendimento médio baixo e países com rendimento médio alto) o indicador índice de mortalidade infantil (IMR) tem um peso factorial estandardizado superior ao dos outros indicadores, vincando a importância e dimensão que o índice de mortalidade infantil representa na qualidade de vida destes países. O facto de se ter estimado o respectivo parâmetro com sinal negativo e com significância estatística justifica o teor desta conclusão. As duas excepções são constituídas pelos países desenvolvidos e países com rendimento baixo. Nos primeiros, o indicador com maior peso factorial corresponde ao índice de percepção ambiental (EPI), o que significa que uma melhor qualidade de vida passa pela sensibilidade que

cada nação tem relativamente aos pressupostos ambientais assumidos no EPI. A segunda excepção é referente aos países com rendimento baixo, onde o indicador com maior peso factorial é o índice de liberdade económica mundial (EFW), vincando a importância e a dimensão que liberdade económica representa na qualidade de vida das populações.

No que concerne à comparação (através de uma simulação de Monte Carlo) das propriedades dos estimadores utilizados nos métodos CBSEM (ML) e PLS, assentes no processo de reamostragem bootstrap, verifica-se que, quer no modelo de medida quer no modelo estrutural, o método CBSEM mostrou ser mais preciso ($viés_{CBSEM} < viés_{PLS}$) que o método PLS. No que diz respeito à eficiência dos estimadores, o método CBSEM (ML) mostrou ser mais eficiente ($SE_{CBSEM} < SE_{PLS}$) que o método PLS nos subgrupos formados pelos países com rendimento baixo, países com rendimento médio baixo, países com rendimento médio alto e países desenvolvidos, não obstante, o método PLS mostrou ser mais eficiente ($SE_{CBSEM} > SE_{PLS}$) que o método CBSEM (ML) nos subgrupos com maior dimensão, nomeadamente nos grupos formados pelos países subdesenvolvidos ($n=147$) e no grupo constituído pela amostra total ($n=215$).

10. Conclusão

No último capítulo desta tese procura dar-se sentido aos resultados obtidos na secção anterior. Serão abordados os resultados mais pertinentes para as hipóteses formuladas, estabelecendo uma relação com a teoria e com os objectivos propostos, assim como as limitações do estudo e sugestões para novas pesquisas.

Na linha do objectivo geral delineado para este trabalho, ou seja, investigar o impacto da qualidade da governança na qualidade de vida das populações, foi constituído, com base na literatura, um modelo conceptual com duas variáveis latentes (Governança e Qualidade de Vida) cujos indicadores reflectissem exactamente o impacto que a qualidade de governança tem na qualidade de vida das populações. Estes indicadores foram criteriosamente seleccionados com base na literatura, de molde a reflectirem o melhor possível as variáveis latentes correspondente. Deste modo, os indicadores relativos à Voz e responsabilização (va), Estabilidade política (sta), Eficácia governamental (eg), Qualidade regulatória (qr), Estado de direito (rl) e Controle da corrupção (cc) foram seleccionados de molde a reflectirem o conceito latente não observável relativo à qualidade de Governança das nações, ao passo que os indicadores relativos à Taxa de literacia total (LT), Facilidade de acesso ao saneamento básico (SN), Índice de mortalidade infantil (IMR), Pegada ecológica (EF), Índice de percepção ambiental (EPI), Liberdade económica mundial (EFW) e ao Produto interno bruto (GDP) foram seleccionados de molde a reflectirem o conceito latente não observável relativo à Qualidade de Vida das nações.

A amostra total contou com 215 países/áreas territoriais que foram posteriormente divididos em cinco grupos de países (países desenvolvidos, países subdesenvolvidos, países com rendimento baixo, países com rendimento médio baixo e países com rendimento médio alto) de acordo com o critério estabelecido pelo banco mundial de dados (World Bank). Deste modo, o modelo conceptual Gov-QV foi ajustado aos cinco grupos de países e à amostra total e foi avaliado de acordo com os dois métodos inerentes à Análise de Equações Estruturais: o método baseado na matriz de covariâncias (CBSEM), cujo estimador de parâmetros é o método da máxima verosimilhança (ML) e o método baseado na matriz de variâncias (VBSEM), cujo estimador de parâmetros corresponde aos mínimos quadrados parciais (PLS). A razão pela qual se utilizaram as duas metodologias reside no facto de que o método VBSEM (PLS) é geralmente empregue quando o método CBSEM (ML) atinge os seus limites, nomeadamente quando as amostras são pequenas (o que acontece quando a amostra total é dividida nos consequentes subgrupos), ou quando os dados não seguem uma distribuição normal (o que se verificou na análise exploratória multivariada), uma vez que o estimador PLS não requer o cumprimento de quaisquer pressupostos.

Os resultados obtidos através do método CBSEM (ML) e VBSEM (PLS) mostraram que, o efeito da variável latente Governança na variável latente Qualidade de Vida das populações se revelou positivo e estatisticamente significativo excepto no grupo formado pelos países com rendimento baixo. Verificou-se também que, no geral, relativamente ao modelo de medida quer avaliado com o método CBSEM (ML) quer avaliado com o método VBSEM (PLS), o indicador estado de direito (rl) se destacou por ter sido o mais explicativo na operacionalização

da variável latente Governança, vincando a importância e a dimensão que o estado de direito representa na qualidade de Governança das nações. Não obstante, no que concerne à variável latente Qualidade de Vida, o indicador relativo à qualidade de saneamento básico (SN) mostrou ser o mais explicativo na operacionalização desta variável quando o modelo de medida foi estimado pelo método CBSEM (ML) ao passo que, quando o modelo de medida foi estimado com o método VBSEM (PLS), o indicador relativo ao índice de mortalidade infantil (IMR) foi o que apresentou, no geral, um maior peso factorial estandardizado.

Finalmente, no que concerne à comparação e avaliação das propriedades dos dois estimadores (ML e PLS) utilizados pelos métodos CBSEM e VBSEM assentes no método de reamostragem bootstrap, verificou-se a partir dos resultados obtidos no teste de Friedman que o viés e os erros padrão dos parâmetros estimados quer pelo estimador ML quer pelo estimador PLS diferem significativamente. Relativamente à precisão do modelo de medida, verificou-se que o viés médio resultante do método VBSEM (PLS) assente no método bootstrap é superior ao viés médio resultante do método CBSEM (ML) assente no método bootstrap. Verificou-se também que, com o método VBSEM (PLS) assente no método bootstrap, os valores mais elevados do viés médio correspondem às amostras de maior dimensão ($n=147$ e $n=215$) sugerindo, deste modo, que o método VBSEM (PLS) assente no método bootstrap sobrestima os pesos factoriais nas amostras de maior dimensão. A mesma situação se verifica no que diz respeito à precisão do modelo estrutural, onde o método CBSEM (ML) assente no método bootstrap se mostra mais preciso em relação método VBSEM (PLS) assente no método bootstrap, sendo este, por sua vez, menos preciso para as amostras de maior dimensão.

Relativamente à eficiência do modelo de medida, verificou-se que, com os dois métodos, a média dos erros padrão vai sendo cada vez menor à medida que o tamanho amostral aumenta. Relativamente à eficiência do modelo estrutural verifica-se que para amostras de maior dimensão o método VBSEM (PLS) assente no método bootstrap se mostra mais eficiente que método CBSEM (ML) assente no método bootstrap, contudo, a situação reverte-se para as amostras de menor dimensão. Neste caso verifica-se também que a partir de um tamanho de $n=58$, a média dos erros padrão vai decrescendo sucessivamente, quer no método CBSEM (ML) assente no método bootstrap, quer no método VBSEM (PLS) assente no método bootstrap.

Limitações e pesquisa futura

Apesar da contribuição deste estudo no que diz respeito à comparação dos dois métodos de estimação inerentes à AEE: ML e PLS; existem naturalmente algumas limitações. As limitações passam principalmente pela simplicidade do modelo conceptual, nomeadamente no que concerne ao relativamente baixo número de indicadores e tamanho amostral reduzido quando se divide a amostra total nos respectivos subgrupos.

Por exemplo, uma razão para o método VBSEM (PLS), mesmo nas amostras de pequena dimensão não ter apresentado a precisão e eficiência desejadas deve-se ao problema conhecido como consistência por aumento. Com efeito, os coeficientes estruturais estimados

através do PLS, convergem para os valores dos parâmetros do modelo composto pelas variáveis latentes em causa à medida que o tamanho amostral e o número de indicadores de cada variável latente tende para infinito, não obstante, nas situações reais da vida quotidiana, nas quais tanto o número de observações como o número de indicadores são finitos, PLS tende a subestimar as correlações entre as variáveis latentes e sobrestimar os pesos factoriais estandardizados (i.e., os parâmetros do modelo de medida; Dijkstra, 1983). Este problema apenas desaparece quando o número de observações e o nº de indicadores por variável latente tende para infinito, uma vez que, nesse caso, os valores caso das variáveis se aproximam dos valores verdadeiros, minimizando este problema (Lohmöller, 1989). Outras limitações consistem no facto de não haver índices de bondade de ajustamento transversais aos dois métodos, e, por esta razão, uma proveitosa pesquisa futura seria investigar, por exemplo, o desempenho do índice de bondade de ajustamento (GOF), que apenas se adequa ao PLS, ao método ML. Outros pontos que seriam úteis investigar no futuro, e no âmbito desta tese, seria o de comparar as propriedades e comportamento dos estimadores PLS e ML, assentes no método de reamostragem bootstrap, conduzindo uma simulação de Monte Carlo em larga escala, onde fosse possível controlar a distribuição e número de indicadores, assim como o número de observações.

Bibliografia

- Adams, W.M. The future of sustainability: re-thinking environment and development in the twenty-first century. In *Proceedings of the IUCN Renowned Thinkers Meeting*, Gland, Switzerland, January 29–31, 2006.
- Anderson, J. C., & Gerbing, D. W. (1984). The effect of sampling error on convergence, improper solutions, and goodness of fit indices for MLE CFA. *Psychometrika*, 49, 155-173.
- Babakus, E., Ferguson, C. E., & Jöreskog, K. G. (1987). The sensitivity of confirmatory maximum likelihood factor analysis to violations of measurement scale and distributional assumptions. *Journal of Marketing Research*, 24(2), 222-228.
- Bagozzi, R. P., & Yi, Y. (1994). Advanced topics in structural equation models. In: Bagozzi, R. P. (Ed.) *Advanced methods of marketing research*. Blackwell, Oxford, pp 1-51.
- Bollen, K. A. (1989). *Structural equations with latent variables*. New York, NY: Wiley.
- Boomsma, A. (1982). Robustness of LISREL against small sample sizes in factor analysis models. In K. G. Joreskog & H. Wold (Eds.), *Systems under indirect observation: Causality, structure, prediction* (Part 1), pp. 149-173. Amsterdam: North Holland.
- Boomsma, A., & Hoogland, J. J. (2001). The robustness of LISREL modeling revisited. In R. Cudeck, S. du Tiout, & D. Sörbom (Eds.), *Structural equation models: Present and future. A Festschrift in honor of Karl Jöreskog* (pp. 139-168). Chicago: Scientific Software International.
- Brown, T. A. (2006). *Confirmatory factor analysis for applied research*. New York, NY: Guilford Press.
- Cassel, C., Hackl, P., & Westlund, A. (1999). Robustness of partial least squares method of estimating latent variable quality structures. *Journal of Applied Statistics*, 26, 435-446.
- Cavaglia, J.L. *Sustainable Agriculture in Brazil*; Edward Elgar: Cheltenham, UK, 1999.
- Chin, W. W. (1998). Issues and opinion on structural equation modeling. *Management Information Systems Quarterly*, 22(1).
- Chin, W. W., & Newsted, P. R. (1999). Structural equation modeling analysis with small samples using partial least squares. In R. H. Hoyle (Ed.), *Statistical strategies for small sample research* (pp. 307-341). Thousand Oaks, CA: Sage.
- Clark, W.; Dickson, N. *Sustainability science: the emerging research program*. Proc. Natl. Acad. Sci. USA 2003, 100, 8059-8061.
- Clark, W. *Sustainability science: a room of its own*. Proc. Natl. Acad. Sci. USA 2007, 104, 1737-1738.
- Curran, P. J., West, S. G., & Finch, J. (1996). The robustness of test statistics to nonnormality and specification error in confirmatory factor analysis. *Psychological Methods*, 1, 16-29.

- Daly, H.; Cobb, J. *For the Common Good: Redirecting the Economy toward Community, the Environment and a Sustainable Future*; Beacon Press: Boston, MA, USA, 1989.
- DeVellis, R. F. 1991 Scale Development: *Theory and Applications*. Newbury Park, CA: Sage.
- Dijkstra, T. (1983). Some comments on maximum likelihood and partial least squares models. *Journal of Econometrics*, 22, 67-90.
- Dunn, S.C., Seaker, R.F., & Waller, M.A. (1994) Latent variables in business logistics research: scale development and validation. *Journal of Business Logistics*, 15, 145-172.
- Ehrenfeld, J. *Sustainability by Design: A Subversive Strategy for Transforming Our Consumer Culture*; Yale University Press: New Haven, CT, USA, 2008; pp. 143-145.
- Enders, C. K., & Bandalos, D. L. (2001). The relative performance of full information maximum likelihood estimation for missing data in structural equation models. *Structural Equation Modeling*, 8(3), 430-457.
- Esty, D.C.; Levy, M.A.; Kim, C.H.; de Sherbinin, A.; Srebotnjak, T.; Mara, V. 2008 *Environmental Performance Index*; Yale Center for Environmental Law and Policy: New Haven, CT, USA, 2008; Available online: <http://epi.yale.edu/> (accessed on 10 December 2009).
- Fornell, C., & Bookstein, F. L. (1982). Two structural equation models: LISREL and PLS applied to consumer exit-voice theory. *Journal of Marketing Research*, 19, 440-452.
- Gerbing, D. W., & Anderson, J. C. (1985). The effects of sampling error and model characteristics on parameter estimation for Maximum Likelihood confirmatory factor analysis. *Multivariate Behavioral Research*, 20, 255-271.
- Gerbing, D. W., & Anderson, J. C. (1993). Monte Carlo evaluations of goodness-of-fit indices for structural equation models. In K. A. Bollen & J. S. Long (Eds.), *Testing structural equation models* (pp. 40-65). Newbury Park, CA: Sage.
- Hair Jr, J.F., Anderson, R.E., Tatham, R.L., & Black, W.C. (2005). *Análise multivariada de dados* (5a. ed.). Porto Alegre: Bookman.
- Hair, J. F., Sarstedt, M., Ringle, C. M., & Mena, J. A. (2012). An assessment on the use of partial least squares structural equation modeling in marketing research. *Journal of the Academy of Marketing Science*, 40, 414-433.
- Hanafi, M. (2007). PLS path modeling: Computation of latent variables with the estimation mode B. *Computational Statistics*, 22, 275-292.
- Haenlein, M., & Kaplan, A. M. (2004). A beginner's guide to partial least squares analysis. *Understanding Statistics*, 3(4), 283-297.
- Henseler, J., & Chin, W. W. (2010). A comparison of approaches for the analysis of interaction effects between latent variables using partial least squares path modeling. *Structural Equation Modeling*, 17, 82-109.

- Hoogland, J. J., & Boomsma, A. (1998). Robustness studies in covariance structure modeling: An overview and a meta-analysis. *Sociological Methods & Research*, 26(3), 329-367.
- Hox, J. J., & Maas, C. J. M. (2001). The accuracy of multilevel structural equation modeling with pseudobalanced groups and small samples. *Structural Equation Modeling*, 8(2), 157-174.
- Hoyle, R.H. (1995). Structural equation modeling: *Concepts, issues and applications*. Thousand Oaks: Sage.
- Hu, L., & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling*, 6, 1-55.
- Hu, L., Bentler, P. M., & Kano, Y. (1992). Can test statistics in covariance structure analysis be trusted? *Psychological Bulletin*, 112(2), 351-362.
- Hulland, J., Ryan, M. J., & Rayner, R. K. (2010). Modeling customer satisfaction: A comparative performance evaluation of covariance structure analysis versus partial least squares. In V. E. Vinzi, W. W. Chin, J. Henseler, & H. Wang (Eds.), *Handbook of Partial Least Squares*. Berlin: Springer-Verlag.
- Hutchinson, S. R., & Bandalos, D. L. (1997). A guide to Monte Carlo simulation research for applied researchers. *Journal of Vocational Education Research*, 22(4).
- Hwang, H., Ho, M. H. R., & Lee, J. (2010). Generalized structured component analysis with latent interactions. *Psychometrika*, 75, 228-242.
- Hwang, H., Malhotra, N. K., Kim, Y., Tomiuk, & Hong (2010). A comparative study on parameter recovery of three approaches to structural equation modeling. *Journal of Marketing Research*, 47, 699-712.
- Hwang, H., & Takane, Y. (2004). Generalized structured component analysis. *Psychometrika*, 69(1), 81-99.
- Jöreskog, K. G., & Sörbom, D. (1982). Recent developments in structural equation modeling. *Journal of Marketing Research*, 19(4), 404-416.
- Jöreskog, K. G., & Wold, H. The ML and PLS techniques for modeling with latent variables: Historical and comparative aspects. In H. Wold & K. Jöreskog (Eds.), *Systems under indirect observation: Causality, structure, prediction II*, (pp. 263- 270). Amsterdam: North-Holland.
- Kates, R.W.; Parris, T.M. *Long-term trends and a sustainability transition*. Proc. Natl. Acad. Sci. USA 2003, 100, 8062-8067.
- Kline, R. B. (2011). Principles and practice of structural equation modeling. New York, NY: Guilford.
- Lee, S. Y., & Song, X. Y. (2004). Evaluation of the Bayesian and maximum likelihood approaches in analyzing structural equation models with small sample sizes. *Multivariate Behavioral Research*, 39, 653-686.

- Lee, S. Y., & Xia, Y. M. (2008). A robust Bayesian approach for structural equation models with missing data. *Psychometrika*, 73(3), 343-364.
- Liu, L. Urban environmental performance in China: a sustainability divide? *Sustain. Dev.* 2009, 17, 1-18
- Liu, L. Sustainability efforts in China: reflections on the Environmental Kuznets Curve through a locational evaluation of —Eco-Communities . *Ann. Assoc. Am. Geogr.* 2008, 98, 604-629.
- Lohmöller, J. –B. (1989). *Latent variable path modeling with partial least squares*. Heidelberg, Germany: Physica Verlag.
- Maas, C. J. M., & Hox, J. J. (2004). The influence of violations of assumptions on multilevel parameter estimates and their standard errors. *Computational Statistics & Data Analysis*, 46, 427-440.
- MacCallum, R. C., Browne, M. W., & Sugawara, H. M. (1996). Power analysis and determination of sample size for covariance structure modeling. *Psychological Methods*, 1, 130-149.
- Marsh, H. W., Hau, K.-T., Balla, J. R., & Grayson, D. (1998). Is more ever too much? The number of indicators per factor in confirmatory factor analysis. *Multivariate Behavioral Research*, 33(2), 181-220.
- Monecke, A., & Leisch, F. (2012). semPLS: Structural equation modeling using partial least squares. *Journal of Statistical Software*, 48(3), 1-32.
- McDonald, R. P. (1996). Path analysis with composite variables. *Multivariate Behavioral Research*, 31(2), 239-270.
- Muthén, L. K., & Muthén, B. O. (1998-2010). *Mplus User's Guide*. Sixth Edition. Los Angeles, CA: Muthén & Muthén.
- Olsson, U. H., Troye, S. V., & Howell, R. D. (1999). Theoretical fit and empirical fit: The performance of maximum likelihood versus generalized least squares estimation in structural equation models. *Multivariate Behavioral Research*, 34(1), 31-58.
- Parris, T.M.; Kates, R.W. Characterizing a sustainability transition: goals, targets, trends, and driving forces. *Proc. Natl. Acad. Sci. USA* 2003, 100, 8068-8073.
- Pasquali, L. (2003) *Psicometria: Teoria dos testes na psicologia e na educação*. Petrópolis: Vozes.
- Paxton, P., Curran, P. J., Bollen, K. K., Kirby, J. B., & Chen, F. (2001). Monte Carlo experiments: Design and implementation. *Structural Equation Modeling*, 8(2), 287-312.
- Porritt, J. *Capitalism as if the World Mattered*; Earthscan: London, UK, 2006; p. 46.
- Reinartz, W. J., Haenlein, M., & Henseler, J. (2009). An empirical comparison of the efficacy of covariance-based and variance-based SEM. *International Journal of Market Research*, 26(4), 332-344.

Ringle, C. M., Götz, O., Wetzels, M., & Wilson, B. (2009). On the use of formative measurement specifications in structural equation modeling: A Monte Carlo simulation study to compare covariance-based and partial least squares model estimation methodologies. In *METEOR Research Memoranda* (RM/09/014): Maastricht University.

Sampaio, Ana. (2011). Uma abordagem com Modelos de Equações Estruturais ao Desenvolvimento Sustentável: Qualidade de Vida, Qualidade de Governança e Pegada Ecológica. *Interfaces de Psicologia, 2º Congresso Nacional*. Universidade de Évora

Sharma, S., Durvasula, S., & Dillon, W. R. (1989). Some results on the behavior of alternate covariance structure estimation procedures in the presence of nonnormal data. *Journal of Marketing Research*, 26, 214-221.

Schumacker, R.E. & Lomax, R.G. (2001). *A beginner's guide to structural equation modeling*. New Jersey: Lawrence Erlbaum Associates

Srinivasan, V., & Mason, C. H. (1986). Nonlinear least squares estimation of new product diffusion models. *Marketing Science* 5, 169-178.

Tanaka, J. S. (1987). "How big is big enough?": Sample size and goodness of fit in structural equation models with latent variables. *Child Development*, 58(1), 134- 146.

Tenenhaus, M. (2008). Component-based structural equation modelling. *Total Quality Management*, 19, 871-886.

Tenenhaus, M., Vinzi, V. E., Chatelin, Y. M., & Lauro, C. (2005). PLS path modeling. *Computational Statistics & Data Analysis*, 48, 159-205.

Ullman, J.B. (2001). Structural equation modeling. In B.G. Tabachnick & L.S. Fidell (Eds.), *Using multivariate statistics* (pp. 653-771). Boston: Ally & Bacon.

Velicer, W. F., & Fava, J. L. (1998). Effects of variable and subject sampling on factor pattern recovery. *Psychological Methods*, 3(2), 231-251.

Vinzi, V. E., Trinchera, L., & Amato, S. (2010). PLS path modeling: From foundation to recent developments and open issues for model assessment and improvement. In V. E. Vinzi et al. (Eds.), *Handbook of Partial Least Squares*. Springer-Verlag: Berlin.

Wold, H. (1975). Path models with latent variables: The NIPALS approach. In H. M. Blalock, A. Aganbegan, F. M. Borodkin, R. Boudon, & V. Capecchi (Eds.), *Quantitative sociology: International perspectives on mathematical and statistical modeling* (pp. 307-357). New York: Academic.

World Commission on Environment and Development (WCED). *Our Common Future*; Oxford University Press: New York, NY, USA, 1987.

Zhang, R.; Zhang, H.; Zhang, R. *Environmental Protection and Sustainable Agricultural Development in China*; Beijing Publishing House: Beijing, China, 2001.

Press Conference on National Day Military Parade, 24 September 2009;

Universal Declaration on Cultural Diversity; United Nations Educational, Scientific and Cultural Organization (UNESCO): Paris, France; 2001.

2005 World Summit Outcome, Resolution A/60/1, Adopted by the General Assembly on 15 September 2005; United Nations General Assembly: New York, NY, USA, 2005.